

Iluminação natural e consumo energético de
edificações não residenciais: aplicação de
redes neurais artificiais

Raphaela Walger da Fonseca

Raphaella Walger da Fonseca

**ILUMINAÇÃO NATURAL E CONSUMO ENERGÉTICO DE
EDIFICAÇÕES NÃO RESIDENCIAIS: APLICAÇÃO DE REDES
NEURAIS ARTIFICIAIS**

Linha de pesquisa: Construção Civil – Conforto Ambiental e Eficiência
Energética das Edificações.

Tese submetida ao Programa de Pós-
Graduação em Engenharia Civil
(PPGEC) da Universidade Federal de
Santa Catarina para a obtenção do grau
de Doutor em Engenharia Civil.

Orientador: Prof. Fernando Oscar
Ruttkay Pereira, Ph.D.

Coorientador: Prof. Dr. Konstantinos
Papamichael, Ph.D.

Florianópolis
2015

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Fonseca, Raphaela Walger da
Iluminação natural e consumo energético de edificações
não residenciais: aplicação de redes neurais artificiais /
Raphaela Walger da Fonseca ; orientador, Fernando Oscar
Ruttkay Pereira ; coorientador, Konstantinos
Papamichael. - Florianópolis, SC, 2015.
457 p.

Tese (doutorado) - Universidade Federal de Santa
Catarina, Centro Tecnológico. Programa de Pós-Graduação em
Engenharia Civil.

Inclui referências

1. Engenharia Civil. 2. Iluminação natural. 3.
Eficiência energética. 4. Redes neurais artificiais. 5.
Edificações. I. Pereira, Fernando Oscar Ruttkay . II.
Papamichael, Konstantinos . III. Universidade Federal de
Santa Catarina. Programa de Pós-Graduação em Engenharia
Civil. IV. Título.

Raphaela Walger da Fonseca

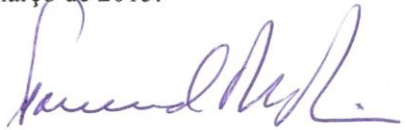
**ILUMINAÇÃO NATURAL E CONSUMO ENERGÉTICO DE
EDIFICAÇÕES NÃO RESIDENCIAIS: APLICAÇÃO DE REDES
NEURAIS ARTIFICIAIS**

Esta Tese foi julgada adequada para obtenção do Título de DOUTOR em Engenharia Civil e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Civil – PPGEC da Universidade Federal de Santa Catarina.

Florianópolis, 09 de março de 2015.

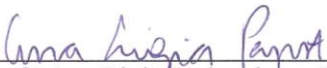


Prof. Roberto Caldas de Andrade
Pinto, Ph.D.
Coordenador do Curso (PPGEC)



Prof. Fernando Oscar Ruttkay
Pereira, Ph.D.
(Moderador/ Orientador) / UFSC

Banca Examinadora:



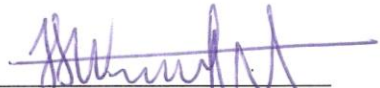
Prof.ª Ana Ligia P. de Abreu, Dr.ª
IFSC



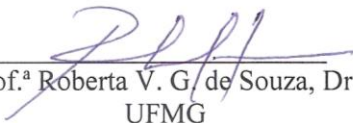
Prof.ª Claudia N. D. Amorim, Dr.ª
UNB



Prof. EneDir Ghisi, Ph.D.
UFSC



Prof. Fernando S. Westphal, Dr.
UFSC



Prof.ª Roberta V. G. de Souza, Dr.ª
UFMG



Prof. Roberto Lamberts, Ph.D.
UFSC

Parte deste trabalho foi realizada no California Lighting Technology Center – CLTC da Universidade da Califórnia – Davis, sob a orientação do professor Konstantinos Papamichael, com financiamento da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, por meio do Programa de Doutorado Sanduíche no Exterior, Proc. n. 12289-12-4. O período de sanduíche ocorreu de 31/12/2012 a 31/08/2013.

Dedico este trabalho com amor aos meus eternos incentivadores: meu marido, Rafael; minha família, Ronaldo, Elmari e Caroline; e meu orientador Fernando O. R. Pereira.

AGRADECIMENTOS

Agradeço a Deus, por ter me guiado para o universo da pesquisa, pelas pessoas que colocou no meu caminho e pelas lições de vida e de conhecimento aprendidas durante o longo período do doutoramento.

Ao meu marido, Rafael, por estar sempre ao meu lado, embarcando comigo nos meus sonhos, compartilhando cada momento, desde se aventurar a passar oito meses na Califórnia a entender a minha ausência e a me dar suporte em todas as atividades cotidianas; por ter sempre palavras acolhedoras nos momentos em que mais precisei e, sobretudo, pelo amor e carinho dedicados.

Aos meus pais, Ronaldo e Elmari, e à minha irmã Caroline, por serem meu porto seguro, meu alicerce, não importando onde eu esteja; pelo amor incondicional, pelo exemplo e por serem sempre tão presentes em todos os momentos da minha vida.

Ao professor, orientador e pai na vida acadêmica, Fernando O. R. Pereira, por ter despertado em mim o deleite pela pesquisa de iluminação natural, por ter me ensinado a pesquisar por amor à ciência, com responsabilidade, sem deixar as outras coisas boas da vida de lado, por me inspirar através de seu exemplo e, principalmente, pela amizade, apoio constante e dedicação que confere a mim e a todos do LabCon.

Ao professor e coorientador Konstantinos Papamichael, pelas incansáveis orientações semanais no período do doutorado sanduíche na UC Davis e pelas orientações via Skype e e-mail depois do meu retorno ao Brasil; por me instigar a examinar todos os resultados detalhadamente em sua essência, por me questionar em tudo, reforçando a minha formação como pesquisadora, e por ter recebido a mim e ao Rafael tão bem no CLTC, tornando-se um amigo.

Aos membros da banca examinadora Ana Ligia Papst de Abreu, Claudia Naves David Amorim, Roberta Vieira Gonçalves de Souza, Eneide Ghisi, Fernando Simon Westphal e Roberto Lamberts, por aceitarem o convite de avaliar este trabalho e pelo esforço de encontrar uma data comum para a realização da banca entre os seus inúmeros compromissos.

Ao professor e diretor do CLTC, Michael Siminovitch, e a todos os colegas, pela recepção acolhedora, troca de experiências e ótimos momentos vividos durante o período de estágio sanduíche.

À CAPES, pelo apoio financeiro concedido durante o período regular de doutoramento e durante o período de doutorado sanduíche nos Estados Unidos.

À Eletrobras, pelo apoio financeiro no último ano de doutoramento.

Ao Programa de Pós-Graduação em Engenharia Civil – PPGEC e à UFSC, pela oportunidade de cursar o doutorado em uma instituição de excelência.

Aos laboratórios LabCon – UFSC, CLTC – UC Davis e LabEEEE – UFSC, pelo espaço físico, equipamentos e bibliografias disponibilizadas.

Aos pesquisadores Christoph Reinhart e Alstan Jakubiec, pelo material bibliográfico cedido e apoio técnico na utilização dos programas Daysim e DIVA/VIPER – Grasshopper. Aos pesquisadores Mudit Saxena e Lisa Heschong, por me receberem no T.R.C. – H. M. G. e pela bibliografia disponibilizada. Ao professor John Mardaljevic, pelo material bibliográfico cedido e assessoramento do trabalho quando da sua vinda ao Brasil por ocasião do Encac 2013.

A todos os amigos do LabCon que me acompanharam nesta jornada e foram minha família de 2010 a 2014 na nossa segunda casa: Adri, Agostinho, Alê, Américo, Ana Beatriz, Ana Jeff, Ana Rocha, Arango, Bianca, Caro Bedoya, Carol Carvalho, Carol DalSóglio, Cata, Cíntia, Eduardo, Eva, Felipe, Fernando O. R. P., Fernando W., Gabi, Gabriel, Isadora, Isaac, Laurits, Lê, Lia, Lúcia, Luíza, Maíra, Marcelo, Marina, Mary, Martin, Nath Braga, Naty Giraldo, Naty Fernandes, Pri Besen, Ravena, Rô, Rupp, Sil, Thay e Veri. Valeu, bolhudos!!!

Agradeço em especial ao D. L. G., Lê e Alê, por terem abraçado a causa insana de desenvolver o nosso monstrinho Emerald. Repito mais uma vez: “– Deu muito trabalho, mas que bom que foi com vocês!”. Vocês foram fantásticos!

Ao professor Fernando Simon Westphal, pelo assessoramento com técnicas de amostragens e equações de regressão e por ter cedido as suas Macro-Excel para a parametrização e as simulações no EnegyPlus. Agradeço também a Mary, Luíza e Maíra, por terem me ensinado a operar as planilhas.

À Evelise Leite Didoné (Evitcha), pela parceria nos tempos de CT-Energ e por ter cedido o material de sua dissertação para a realização do Capítulo 4 deste trabalho.

À Natália Fernandes e Isadora Pauli Custódio, pela ajuda nas simulações no Daysim e na tabulação dos dados utilizados para o zoneamento de iluminação natural, utilizado no Capítulo 8.

À Carol DalSóglio, pelas imagens para a qualificação, em especial, a imagem das mãos iluminadas que estiveram em todas as apresentações do trabalho.

A todos os amigos do LabEEE e ao professor Roberto Lamberts, por tornarem leve e alegre a minha dupla jornada LabCon – LabEEE durante este último ano. Em especial, a Andrea Triana, Rogério, Márcio, Re, Miguel, Ana, Miche, Clarissa, Cláudia D., Devis, Gabriel, Andrea (Manooo), Ju Cruz, Alexandre, Aline, Bruna, Vanessa, Léo e Karran. Por fim, aos meus queridos amigos do NC Veri, Elisa, Gustavo, Letícia, Mirella, Amadeus e Júlia, não tenho palavras para agradecer a parceria de vocês nos últimos meses de finalização do doutorado, tenho muita sorte de trabalhar com pessoas tão especiais como vocês!

Ao professor Mauro Roisenberg, por aceitar uma arquiteta estranha no ninho, na disciplina de Inteligência Artificial Conexionista do PPGCC do INE, e por seguir me assessorando até o fim do trabalho, mesmo com reuniões via Skype no período do doutorado sanduíche.

Aos amigos Daia e Isaac, por estarem sempre prontos a me ajudar no desbravamento das redes neurais artificiais e a desmistificar a linguagem de programação do MATLAB.

Aos amigos Sacola e Leco, por me assessorarem com suas visões de engenheiros na interpretação dos dados do zoneamento de iluminação natural, utilizado no Capítulo 8. Em especial ao Sacola, pelas várias horas que passamos tentando encontrar relações em meio a um mundo de planilhas e dados.

Aos amigos Carol e Marcelo, pela parceria no LabCon-LabEEE, caronas, vizinhança e tudo mais. Em especial, por cuidarem da nossa casa e do nosso carro durante o período do doutorado sanduíche.

À Laurits, pela amizade e por ter cuidado da nossa casa durante o período do doutorado sanduíche.

À Veri, pela amizade, parceria que começou no LabCon e se estendeu ao LabEEE, e por ter revisado este trabalho antes do envio para a banca.

À Rosi, pelas aulas de inglês na preparação para o doutorado sanduíche, regadas a deliciosos cafés, pelo constante apoio com revisões de textos e amizade construída.

À Isabel, pela disponibilidade e atenção dispensadas na revisão do texto em pleno Carnaval.

À Nat Giraldo, por transformar todas as cores base do Windows em uma apresentação impecável! Ao Rupp, pela paciência de esperar até tarde da noite enquanto a Nat me ajudava a fazer tal milagre. E à Elisa Beck, que, com os seus dons artísticos, deu o toque final à apresentação.

Às DIVAS Ane, Julis e Veri, pela amizade e apoio, por acompanharem meu crescimento desde a época do mestrado e estarem sempre presentes em todos os momentos.

Às “Amigows” Elisa, Caro, Bi, Carol, Fer, Gabi, Miki e Nay, pela amizade, por terem entendido a minha ausência durante este período, sem deixar que a distância interferisse na nossa amizade.

A todos os amigos que conheci em Davis, em especial a Marcela, Pancho, Carolyn, Brian, Zitta, Becky, Jeff, Hana, Chavi, Paola, Gabriel, Melissa, Joyce, Tristan, Bernard, Tom, Kim e Taka. *Guys, you are awesome; I'll never forget our time together!*

À Turma do Surf, pela companhia nos momentos de descanso, por entenderem a minha ausência e pela torcida pela finalização do trabalho.

Aos amigos da SRF, pelos momentos de quietude, paz e energias positivas enviadas que me ajudaram a manter o equilíbrio durante os períodos de pressão do doutorado.

A toda a minha família, em especial à Cole, por compartilhar comigo do outro lado do mundo a aventura de ser uma doutoranda e por revisar os meus textos em inglês. Às minhas tias Beth e Eliane, pelas boas vibrações e carinho. Aos meus avós que daqui ou do alto estiveram sempre comigo. A Thalissa, por entender a minha ausência durante as suas visitas e estar sempre presente mesmo de longe.

Aos Gourmets, pelos momentos de descanso que passamos “em família”, por cuidarem dos meus pais e da minha Shive enquanto eu estava me dedicando ao doutorado e pelo carinho e torcida para que eu concluísse este projeto. Em especial, pelas delícias da tia Ana e da Ilona, que tornaram mais gostosos os momentos em que não tínhamos tempo de cozinhar por causa do trabalho.

Aos professores e às colegas das escolas de dança Athené Tamisiere e Pamela Trokanski Dance Workshop, aos professores e colegas de yoga da UFSC e da International House e aos professores de yoga e ginástica da Elase que me ajudaram a equilibrar as longas horas em frente ao computador com a saúde física de maneira alegre e descontraída. A Lígia, Camila, Arthur e Marcelo, que me ajudaram a “ter braço” para acabar a revisão do texto.

Aos exemplos do esporte Guga, Nadal e Medina, que através da sua disciplina e força de vontade me inspiraram a “jogar sempre um novo ponto” e a “ter paciência de esperar as ondas se formarem”.

E, por fim, a todos aqueles que, de alguma forma, contribuíram para o desenvolvimento deste trabalho e para o meu crescimento pessoal e profissional.

(...) não pode haver trevas onde existe
luz.

Paramahansa Yogananda, 1893-1952

RESUMO

Raras ferramentas simplificadas oferecem a possibilidade de avaliar o impacto do aproveitamento da luz natural no consumo energético de edificações de forma completa devido à dificuldade de modelar a sua dupla influência: no sistema de iluminação artificial e condicionamento de ar. Este trabalho teve por objetivo investigar as possibilidades e as limitações da aplicação de redes neurais artificiais (RNAs) para estimar o potencial energético do aproveitamento da iluminação natural em edificações não residenciais por meio da metamodelagem de suas variáveis-chave. O método adotado apresentou duas etapas: a primeira, de abordagem sistemática investigativa; e a segunda, de abordagem propositiva. Na etapa investigativa, identificou-se a necessidade de avaliar o desempenho das RNAs diante de técnicas estatísticas já estudadas, adotando-se a regressão linear multivariada (RLM), e de avaliar o potencial das RNAs para a metamodelagem das principais variáveis-chave da iluminação natural referentes: a descrição, a localização e o desempenho do edifício. Para a comparação entre a precisão dos modelos RNA e RLM, repetiu-se um estudo anterior que propôs uma equação baseada em RLM para modelar uma zona termoluminosa, propondo-se uma RNA e comparando-se a precisão das técnicas. A investigação das variáveis da descrição do edifício teve como principal norteador a verificação do potencial das RNAs para modelar variáveis que operam em diferentes escalas. A investigação das variáveis do contexto do edifício avaliou o potencial das redes para modelar o comportamento de edificações em diferentes climas. Para a investigação das variáveis de desempenho do edifício, as redes foram testadas diante de diferentes agrupamentos de variáveis de desempenho de iluminação natural e de consumo energético. Essas avaliações foram desenvolvidas conforme: a) a seleção das variáveis; b) a amostragem dos dados (direcionada ou aleatória através de Hipercubo Latino); c) a simulação energética (EnergyPlus e *plug-in* DIVA do programa Rhinoceros, conforme a etapa do estudo priorizasse tempo ou precisão da simulação); d) o treinamento da RNA; e e) a análise dos resultados e a definição da ação seguinte. Para a realização das simulações integradas no DIVA, propôs-se um algoritmo de parametrização desenvolvido no *plug-in* Grasshopper, que permite a simulação de mais de 10 milhões de casos diferentes. A metamodelagem baseou-se em uma única zona termoluminosa, partindo-se da rede mais simples que pudesse aprender e generalizar soluções. A acurácia das RNAs foi verificada através da utilização de novos modelos, com características diferentes das conhecidas pela rede. A abordagem propositiva do método dispôs um método simplificado para determinar a redução do consumo energético de edifícios devido ao aproveitamento da iluminação natural. A

variável de saída da RNA foi a Densidade de Potência de Iluminação em Uso (DPU), que é ponderada pela área de zonas de iluminação natural para determinar a DPU do edifício. Para a definição da área das zonas, foram propostas equações que consideraram o dinamismo do clima. Como resultado, 799 redes foram testadas diante de 19 variáveis da descrição, 14 do contexto e 15 do desempenho do edifício. Foram simulados 12.041 casos (21.187 simulações de iluminação natural e termoenergéticas). Os resultados da etapa investigativa apontaram as RNAs como método mais preciso que a RLM, a ponto de melhorar o coeficiente de determinação de 0,62 para 0,99. Quanto à investigação das variáveis da descrição do edifício, as RNAs foram capazes de modelar a influência dos parâmetros orientação, percentual de abertura da fachada e transmissão visível com erro percentual inferior a 5%. Quanto ao contexto do edifício, os melhores resultados foram obtidos agrupando-se variáveis de localização geográfica, características térmicas e disponibilidade de luz e considerando-se cidades de diferentes hemisférios na mesma rede, num total de 11 climas. Quanto às variáveis de desempenho, as redes apresentaram maior facilidade na predição das variáveis de consumo energético isoladamente do que de medidas de iluminação natural isoladamente ou de ambos na mesma rede. Quanto à etapa propositiva, o método simplificado resultou em erros inferiores a 5% quando comparado à simulação computacional. Como conclusão geral, as RNAs apresentaram elevado potencial para serem utilizadas em métodos simplificados de iluminação natural sob o enfoque energético para diversas localidades com precisão superior à RLM. Os objetivos do trabalho foram cumpridos, visto que se obteve um panorama das potencialidades da metamodelagem da iluminação natural utilizando RNAs diante de suas principais variáveis-chave e das estruturas de RNAs mais difundidas para a representação de funções. Como principal contribuição social e prática do trabalho, destacam-se um método passível de ser aplicado em todo o território nacional e a contribuição para códigos e normas locais. Como contribuição científica e teórica, destaca-se o avanço nos estudos de aplicação de inteligência artificial para a modelagem dos fenômenos físicos dinâmicos no ambiente construído (luminoso e térmico).

Palavras-chave: Iluminação natural. Eficiência energética. Redes neurais artificiais.

ABSTRACT

Few simplified tools offer the possibility of evaluating the impact of comprehensively using daylighting on energy consumption, since it is difficult to model its dual influence: on the artificial lighting system and on air conditioning. This work aimed at investigating the possibilities and the limitations of applying artificial neural networks (ANN) to predict daylight harvesting in non-residential buildings through metamodeling its key variables. There are two stages in the adopted method: the first one used a systematic investigative approach and the second one used a purposeful approach. In the investigative stage, it was identified the necessity of evaluating the ANN performance by adopting multivariate linear regression (MLR) facing other traditional statistical techniques, and to assess the ANNs potential for metamodeling the main daylighting key variables referring to: building description, building location and building performance. In order to compare the accuracy of ANN and MLR models, a previous study that had proposed a RLM-based equation to model a luminous-thermal zone was repeated, by proposing an ANN and comparing the accuracy of the techniques. The investigation of the building description variables was mainly guided by the verification of the ANNs potential, in order to model variables that operate at different scales. The investigation of the building context variables aimed at verifying the networks potential to model the buildings behavior in different climates. In order to research the variables related to building performance, different grouping parameters connected to daylighting and energy consumption were tested. The evaluation actions were developed according to: a) variables selection; b) sampling data (directed or random by Latin Hypercube); c) energy simulation (EnergyPlus and plug-in DIVA Rhinoceros software, when the study stage prioritized time or simulation accuracy); d) ANN training and e) results analysis and next actions definition. In order to perform the integrated simulations into DIVA, a parameterization algorithm developed at the Grasshopper plug-in that allows the simulation of more than 10 million different cases was proposed. The metamodel experiments were based on interactions using only one luminous-thermal zone and it started from the simplest network that could learn and generalize solutions. The accuracy of the ANNs was verified by using new models, whose characteristics were different from the ones that were already known by the network. The purposeful approach of the method disposed a simplified process for determining the reduction of buildings energy consumption due to the daylighting harvesting. The ANN output variable was the Lighting Density Power in Use (LDPU), which is weighted by the daylit to determine the building LDPU. Aiming at computing the daylit zones area, equations that consider the weather dynamism were proposed. As a result, 799

networks were tested facing 19 building description, 14 building context and 15 building performance key variables. 12,041 cases were simulated (21,187 daylighting, thermal and energy simulations). The investigative stage results indicated that the ANNs were a more accurate method than the linear regression, since the determination coefficient improved from 0.62 to 0.99. Regarding the investigation of the building description variables, the ANNs were able to model the influence of the following parameters: orientation, window to wall ratio and visible transmission, showing a percentage error lower than 5%. Concerning the building context, the best results were obtained by grouping variables regarding: geographic location, thermal characteristics and daylight availability. It considered cities from different hemispheres in the same ANN, adding up 11 different climates. The percentage error of the best network solution was lower than 10%, thus it was higher than 30% for the test set individually. On the subject of building performance parameters, the networks showed better results when predicting the energy consumption parameters separately than when predicting daylighting parameters independently, or when both of them were in the same network. Respecting the purposeful approach stage, the simplified method error was lower than 5% when compared to the computer simulation. As a general conclusion, it can be stated that the ANN technique shows a potential for being applied to develop simplified daylighting methods in line with the energy approach for multiple locations with greater precision than the MLR. The research goals have been met, since it was possible to obtain an overview of the potential using ANNs to daylighting metamodeling facing its main key variables and the most widespread ANNs structures. The main social / practical contribution of this research is the possibility of applying the method across the country and contributing to local codes and standards. As a scientific / theoretical contribution, it can be highlighted the progress in studies on artificial intelligence application for metamodeling dynamic physical phenomena in the built environment (luminous and thermal).

Keywords: Daylighting. Energy efficiency. Artificial neural networks.

LISTA DE FIGURAS

Figura 1 – Construção de metamodelos de simulação computacional.....	44
Figura 2 – Mapa conceitual da tese.....	48
Figura 3 – Quadro de análise de iluminação natural proposto pelo Comitê de Iluminação Natural da IES.....	61
Figura 4 – Modelo não linear de um neurônio artificial	73
Figura 5 – Funções de ativação.....	75
Figura 6 – Exemplo de rede alimentada adiante ou acíclica (<i>feedforward</i>) com uma única camada de neurônios	77
Figura 7 – Exemplo de rede alimentada adiante ou acíclica (<i>feedforward</i>) totalmente conectada com uma camada oculta e uma camada de saída	78
Figura 8 – Exemplo de rede recorrente com neurônios ocultos	79
Figura 9 – Detalhe do funcionamento de uma rede PMC com algoritmo da retropropagação do erro	84
Figura 10 – Exemplo de aproximação da função seno ruidosa antes e depois da aplicação da Regularização Bayesiana.....	87
Figura 11 – Distribuição de artigos sobre RNAs encontrados por assunto de interesse deste trabalho	90
Figura 12 – Esquema das etapas metodológicas da pesquisa (base para quadro resumo dos resultados – disponível no APÊNDICE G).....	103
Figura 13 – Esquema conceitual da simulação parametrizada.....	110
Figura 14 – Conceito da metamodelagem utilizada (Etapa 3 da Figura 12) ...	113
Figura 15 – Esquema da Validação Cruzada com K = 3 tentativas	115
Figura 16 – Resumo das ações metodológicas abordadas nos próximos capítulos relacionadas às perguntas de pesquisa e aos objetivos específicos	123
Figura 17 – Aplicação da etapa metodológica 3: avaliação do potencial das RNAs frente à RLM.....	127
Figura 18 – Esquema da geometria dos modelos de Didoné (2009).....	128
Figura 19 – Consumo anual de energia Simulado x Equacionado por RLM ..	132
Figura 20 – Consumo anual de energia Simulado x Calculado pela RNA através da função <i>logsig</i>	137
Figura 21 – Resumo do processo da avaliação sistemática: descrição do edifício	149
Figura 22 – Aplicação da etapa metodológica 3: descrição do edifício	150
Figura 23 – Planta baixa da geometria-base utilizada neste capítulo.....	151
Figura 24 – Diagrama de caixas legendado (Box plot ou Box-and-Whisker Charts).....	156
Figura 25 – Abordagens para variáveis cíclicas (ou polares).....	157
Figura 26 – Aplicação dos gráfico bolha para avaliar a inter-relação das variáveis frente ao fenômeno	158

Figura 27 – Comparação entre as redes da valiação cruzada do Matlab: (a) e (b) separado por uso final; e (c) e (d) média dos usos finais (rede completa) para os mesmos conjuntos.....	164
Figura 28 – Comparação entre as duas redes de melhor desempenho do Matlab e a rede do EasyNN para cada variável-chave de entrada agrupadas por uso final para o conjunto “nunca vistos”	165
Figura 29 – Verificação do efeito da inclusão de <i>Ventiladores</i> como parâmetro de saída nas redes.....	168
Figura 30 – Comparação entre redes neurais de mesma configuração para 3 e 2 parâmetros na camada de entrada	170
Figura 31 – Comparação entre as redes com parâmetros de saída energéticos, de iluminação e ambos	171
Figura 32 – Desempenho das redes para diferentes critérios de parada – conjunto “nunca vistos”	173
Figura 33 – Comparação do desempenho para os diferentes critérios de parada destacando-se graficamente o menor erro para o conjunto validação	174
Figura 34 – Arquiteturas das três redes testadas	175
Figura 35 – Comparação entre as três arquiteturas de rede para cada padrão de saída.....	176
Figura 36 –Comparação do efeito do número de neurônios no desempenho da rede através de diagramas de caixas	177
Figura 37 – Identificação dos modelos referentes aos valores discrepantes – EPAM global das redes.....	178
Figura 38 – Comparação entre o desempenho de cada uma das 10 RNAs para cada orientação para a combinação T_{VIS} 0,57 e PAF 20% (parâmetro de saída: Consumo Total - EPAM).....	180
Figura 39 – Comparação entre o desempenho da média das 10 RNAs para cada caso: agrupamento por combinação PAF e T_{VIS} para as três codificações (parâmetro de saída: Consumo Total)	181
Figura 40 – Comparação dos efeitos do aumento da quantidade de padrões no treinamento: resultado do conjunto de treinamento	182
Figura 41 – Comparação dos efeitos do aumento da quantidade de padrões no treinamento: resultado do conjunto “nunca vistos”.....	182
Figura 42– Comparação entre o consumo de duas geometrias: ambiente profundo e ambiente largo, para as 17 orientações separado por uso final.....	184
Figura 43 – Visualização do padrão de Consumo Energético Total em função da Orientação, T_{VIS} e PAF.....	185
Figura 44 – Visualização do padrão de Consumo de energia para Aquecimento em função da Orientação, T_{VIS} e PAF	186
Figura 45 – Visualização do padrão de Consumo de energia para Resfriamento em função da Orientação, T_{VIS} e PAF	187

Figura 46 – Visualização do padrão de Consumo de energia para Iluminação em função da Orientação, T_{VIS} e PAF	188
Figura 47 – Descrição das etapas de inclusão de padrões no conjunto de treinamento	189
Figura 48 – Comparação entre o desempenho de uma das 10 RNAs: agrupamento por orientação Oeste e variável a ser observada (PAF ou T_{VIS}) (parâmetro de saída: Consumo Total)	191
Figura 49 – Efeito da inclusão de novos casos de PAF no treinamento da rede considerando o consumo dos quatro usos finais.	193
Figura 50 – Efeito da inclusão de novos casos de T_{VIS} no treinamento da rede considerando o consumo dos quatro usos finais.	195
Figura 51 – Adição de padrões ao conjunto de treinamento para PAF, avaliado segundo EPAM do parâmetro Consumo de Iluminação	197
Figura 52 – Identificação da ocorrência dos maiores erros para PAF – parâmetro de saída iluminação.....	198
Figura 53 – Identificação da ocorrência dos maiores erros para T_{VIS} – parâmetro de saída iluminação.....	199
Figura 54 – Efeito da inclusão dos novos padrões para PAF – parâmetro de saída iluminação.....	200
Figura 55 – Efeito da inclusão dos novos padrões para T_{VIS} – parâmetro de saída iluminação.....	201
Figura 56 – Descrição das etapas de inclusão de padrões no conjunto de treinamento considerando a inclusão do parâmetro FS	203
Figura 57 – Efeito da inclusão do parâmetro FS nas redes, separado por conjunto de treinamento e por parâmetro de saída para PAF e T_{VIS}	204
Figura 58 – Comparação entre redes com todos os parâmetros de saída e com cada parâmetro de forma isolada.....	205
Figura 59 – Comparação entre redes com todas as orientações agrupadas ou isoladas	207
Figura 60 – Comparação entre as redes Gradiente Descendente com 6 e 10 neurônios e para as redes Levenberg-Marquardt e Regularização Bayesiana.....	208
Figura 61 – Verificação dos erros e_t de cada caso individualmente destacando o sinal para Gradiente Descendente de seis neurônios.....	209
Figura 62 – Verificação dos erros e_t de cada caso individualmente destacando o sinal para Gradiente Descendente de 10 neurônios.....	209
Figura 63 – Estudo das curvas de tendência da redução do erro da rede para o conjunto “nunca vistos” frente aumento do número de casos do treinamento	212
Figura 64 – Resumo da avaliação sistemática: contexto do edifício	214
Figura 65 – Aplicação da etapa metodológica 3: contexto do edifício	215
Figura 66 – Comparação entre os algoritmos para cada o uso final para a média das 5 RNAs	224

Figura 67 – Comparação entre os algoritmos destacando-se o uso final para cada RNA individualmente	224
Figura 68 – Comparação entre os algoritmos, destacando-se o uso final para os três conjuntos da rede	226
Figura 69 – Comparação entre a quantidade de neurônios na camada intermediária separado por uso final para os três conjuntos da rede	229
Figura 70 – Comparação entre os agrupamentos de padrões de entrada da rede para cada uso final para os três conjuntos da rede	231
Figura 71 – Comparação entre os agrupamentos de padrões de entrada da rede para cada uso final para os três conjuntos da rede	232
Figura 72 – Comparação entre os agrupamentos com ajuste de número de neurônios para cada uso final para os três conjuntos da rede	233
Figura 73 – Comparação entre as soluções com as cidades dos dois Hemisférios e apenas do Hemisfério Sul	234
Figura 74 – Limites adotados para cada parâmetro de entrada	236
Figura 75 – Comparação entre os resultados antes e depois da troca de cidades para uma solução com Ambos os Hemisférios	237
Figura 76 – Comparação entre os resultados antes e depois da troca de cidades para as soluções Hemisfério Sul e Ambos os Hemisférios para o conjunto total de dados	238
Figura 77 – Comparação entre as soluções com diferentes variáveis térmicas, destacando-se o uso final para cada um dos três conjuntos da rede	241
Figura 78 – Comparação entre as soluções com diferentes variáveis térmicas, destacando-se o uso final para todo o conjunto de dados da rede ..	242
Figura 79 – Comparação entre as soluções com diferentes variáveis da disponibilidade de luz, destacando-se o uso final para cada um dos três conjuntos da rede	244
Figura 80 – Comparação entre as soluções com diferentes variáveis da disponibilidade de luz, destacando-se o uso final para todo o conjunto de dados da rede.....	245
Figura 81 – Comparação entre o desempenho da rede testada conforme método da literatura e conjunto “nunca vistos”, destacando-se o uso final para cada um dos três conjuntos da rede.....	246
Figura 82 – Comparação entre o desempenho da rede testada conforme método da literatura e conjunto “nunca vistos”, destacando-se o uso final para todo o conjunto de dados da rede	247
Figura 83 – Resumo do processo da avaliação sistemática: desempenho do edifício.....	253
Figura 84 – Aplicação da etapa metodológica 3 – desempenho do edifício	254
Figura 85 – Esquema das etapas da investigação conforme amostragem e seleção de parâmetros para as análises	256
Figura 86 – Modelo da zona termoluminosa e parâmetros variados.....	264

Figura 87 – Exemplo da variação de distribuição e tamanho das aberturas zenitais (PAZ)	268
Figura 88 – Exemplo das variações de proteções solares (AVS e AHS)	268
Figura 89 – Algoritmo gerado no Grasshopper, legendado de acordo com as área das funções realizadas	275
Figura 90 – Número de casos por parâmetros para as amostragens feitas pelo método Hipercubo Latino para 100, 200 e 300 casos	277
Figura 91 – Perfil de distribuição por frequência de ocorrência dos resultados dos parâmetros de saída resultantes das amostras por Hipercubo Latino para 300, 200 e 100 casos	279
Figura 92 – Comparação entre as quantidade de neurônios na camada interna para a amostra de 300 casos para todo o conjunto de dados das redes	280
Figura 93 – Comparação entre os algoritmos para a amostra de 300 casos para todo o conjunto de dados das redes, considerando a média das três RNAs	281
Figura 94 – Comparação entre as três amostras, considerando todos os parâmetros de saída na mesma RNA, para todo o conjunto de dados da rede.....	282
Figura 95 – Comparação entre as três amostras, considerando os parâmetros de saída de Consumo Energético, para todo o conjunto de dados da rede	284
Figura 96 – Comparação entre as três amostras, considerando os parâmetros de saída de Iluminação Natural, para todo o conjunto de dados da rede	285
Figura 97 – Comparação entre os quatro agrupamentos de variáveis de desempenho para todo o conjunto de dados das redes (descrição do edifício).....	287
Figura 98 – Comparação entre os três agrupamentos de variáveis de desempenho, excluindo-se DL+DPU para cada conjunto de dados da rede (descrição do edifício).....	289
Figura 99 – Comparação entre as três soluções da combinação de parâmetros Energia + DL para cada conjunto de dados da rede (descrição do edifício).....	291
Figura 100 – Comparação entre as duas soluções para as redes DPU para cada conjunto de dados da rede (descrição do edifício)	292
Figura 101 – Comparação entre as diferentes abordagens de teste das redes para cada conjunto de dados da rede (descrição do edifício)	293
Figura 102 – Resultado da precisão da rede para estimar a DPU para cada caso do conjunto “nunca vistos” – parâmetros da descrição do edifício	295
Figura 103 – Resultado da precisão da rede para estimar a DPU para cada grupo de casos do conjunto “nunca vistos” – iluminância-alvo	296

Figura 104 – Comparação entre todas as redes abordadas neste capítulo para todo o conjunto de dados das redes (descrição e contexto do edifício)	297
Figura 105 – Comparação entre todas as redes abordadas neste capítulo, excluindo-se DL+DPU para cada conjunto de dados da rede (descrição e contexto do edifício)	299
Figura 106 – Comparação entre as redes com parâmetros de iluminação natural para cada conjunto de dados da rede (descrição e contexto do edifício).....	301
Figura 107 – Comparação entre as redes com parâmetros de energia para cada conjunto de dados da rede (descrição e contexto do edifício).....	302
Figura 108 – Comparação entre as redes com os parâmetros DPU para cada conjunto de dados da rede descrição e contexto do edifício)	303
Figura 109 – Resultado da precisão da rede para estimar a DPU para cada caso do conjunto “nunca vistos” – parâmetros da descrição do edifício para as três cidades (descrição e contexto do edifício)	305
Figura 110 – Resultado da precisão da rede para estimar a DPU para cada grupo de casos do conjunto “nunca vistos” – iluminância-alvo (descrição e contexto do edifício)	306
Figura 111 – Resultado da precisão da rede para estimar a DPU para cada grupo de casos do conjunto “nunca vistos” – localidades (descrição e contexto do edifício)	306
Figura 112 – Quadro de análise de iluminação natural, destacando-se o enfoque do método proposto	313
Figura 113 – Partido conceitual da proposta de zoneamento dinâmico	315
Figura 114 – Relação entre o percentual de obstrução de visão do entorno e o FO	317
Figura 115 – Exemplo de representação gráfica do zoneamento	320
Figura 116 – Mapas médios de zoneamento (300 e 500 lux) separados por PAF e orientação	325
Figura 117 – Representação gráfica dos modelos indicando onde passa a linha média e o cruzamento das profundidades das zonas com os limites estabelecidos pelas “Regras Práticas”	326
Figura 118 – Valores de DA por modelo na linha média para iluminância de projeto de 300 lux e cruzamento das profundidades das zonas com os limites estabelecidos pelas “Regras Práticas”	328
Figura 119 – Valores de DA por modelo na linha média para iluminância de projeto de 500 lux e cruzamento das profundidades das zonas com os limites estabelecidos pelas “Regras Práticas”	329
Figura 120 – Valores de DA por modelo na linha média para iluminância de projeto de 100 lux e cruzamento das profundidades das zonas com os limites estabelecidos pelas “Regras Práticas”	330
Figura 121 – Comparação dos valores simulados e calculados através das equações para 300 lux separadas por PAF	335

Figura 122 – Comparação dos valores simulados e calculados através das equações para 500 lux separadas por PAF	335
Figura 123 – Representação da determinação da largura da zona em planta e cruzamento das larguras-limite estabelecidas pelas “Regras Práticas” – Janela 1	336
Figura 124 – Representação da determinação da largura da zona em planta e cruzamento das larguras-limite estabelecidas pelas “Regras Práticas” – Janela 2	337
Figura 125 – Exemplo de comparação entre os modelos dos dois conjuntos de simulação: com 5 <i>bounces</i> e com 2 <i>bounces</i>	339
Figura 126 – Valores para o Fator de Ajuste de DPU para a Zona Z2 e correlação entre FA_{DPU} e a diferença entre $DA_{médio}$ para Z1 e Z2 .	341
Figura 127 – Representação gráfica da aplicação do zoneamento	345
Figura 128 – Comparação dos resultados da área da Zona Z1 simulados no Daysim e nos Equacionados para PAF 80% 500 lux	349
Figura 129 – Comparação dos resultados da área da Zona Z2 simulados no Daysim e nos Equacionados para PAF 80% 500 lux	349
Figura 130 – Diagrama de critérios para definição de adequabilidade da Autonomia da Luz Natural Espacial	355
Figura 131 – Exemplo da análise dos métodos simplificados segundo os critérios exibidos no Quadro 3	410
Figura 132 – Comparação entre o desempenho de cada uma das 10 RNAs para cada orientação para as diversas combinações entre T_{VIS} e PAF: Consumo Total.....	426
Figura 133 – Comparação entre o desempenho da média das 10 RNAs cada orientação para as diversas combinações entre T_{VIS} e PAF: para os quatro parâmetros de saída e a codificação cardeal.....	427
Figura 134 – Comparação entre o desempenho da média das 10 RNAs para cada orientação para as diversas combinações entre T_{VIS} e PAF: para os quatro parâmetros de saída e a codificação cíclica.....	428
Figura 135 – Comparação entre o desempenho da média das 10 RNAs para cada orientação para as diversas combinações entre T_{VIS} e PAF: para os quatro parâmetros de saída e a codificação cardeal + 359° N.....	429
Figura 136 – Comparação entre EPAM médio das 10 redes separado isolando-se PAF para orientação 0° e 90°.....	432
Figura 137 – Comparação entre EPAM médio das 10 redes separado isolando-se PAF para orientação 180° e 270°.....	433
Figura 138 – Comparação entre EPAM médio das 10 redes separado isolando-se T_{VIS} para orientação 0° e 90°	434
Figura 139 – Comparação entre EPAM médio das 10 redes separado isolando-se T_{VIS} para orientação 180° e 270°.....	435
Figura 140 – Perfil de distribuição das amostras por Hipercubo latino para 300, 200 e 100 casos por parâmetro de saída: Aquecimento e Resfriamento.....	438

Figura 141 – Perfil de distribuição das amostras por Hipercubo latino para 300, 200 e 100 casos por parâmetro de saída: Iluminação e Equipamentos	439
Figura 142 – Perfil de distribuição das amostras por Hipercubo latino para 300, 200 e 100 casos por parâmetro de saída: sDA 50%	440
Figura 143 – Perfil de distribuição das amostras por Hipercubo latino para 300, 200 e 100 casos por parâmetro de saída: sUDI 30% e sUDI 50%	441
Figura 144 – Perfil de distribuição das amostras por Hipercubo latino para 300, 200 e 100 casos por parâmetro de saída: sFLD30% e sFLD 50%	442
Figura 145 – Perfil de distribuição das amostras por Hipercubo latino para 300 casos por parâmetro de saída em escala logarítmica: energia	443
Figura 146 – Perfil de distribuição das amostras por Hipercubo latino para 300 casos por parâmetro de saída em escala logarítmica: iluminação natural	444
Figura 147 – Miniatura do mapa- resumo relacionando método e resultados	454

LISTA DE TABELAS

Tabela 1 – Duração da simulação de iluminação natural para ambientes de diferentes complexidades utilizando diferentes programas (algoritmos).....	66
Tabela 2 – Características construtivas, de uso, ocupação e iluminação	129
Tabela 3 – Variáveis da descrição do edifício adotadas para o teste da rede utilizando o conjunto “nunca vistos”	135
Tabela 4 – Comparativo entre os resultados obtidos através das duas arquiteturas de redes, com função de transferência <i>logsig</i> e <i>tansig</i> (erros normalizados)	136
Tabela 5 – Resultados da calibração entre os modelos simulados por Didoné (2009) e os simulados para este trabalho	138
Tabela 6 – Resultado do desempenho de cada RNA da validação cruzada do grupo <i>logsig</i>	139
Tabela 7– Resultados das estimativas das RNAs para os casos do conjunto “nunca vistos”	140
Tabela 8 – Comparação das relações geométricas entre os modelos e seus respectivos consumos energéticos destacados por uso final.	143
Tabela 9 – Cruzamento dos valores de PAF e T_{VIS} e os Valores de Abertura Efetiva resultantes destacando-se os adotados deste trabalho	169
Tabela 10 – Dados das cidades escolhidas para o treinamento e o teste das redes neurais.....	222
Tabela 11 – Tempo médio de processamento de cada algoritmo.....	226
Tabela 12 – Valores adotados para os novos parâmetros da descrição das características térmicas	240
Tabela 13 – Valores adotados para Iluminância Global Horizontal Acumulada	243
Tabela 14 – Parâmetros do Radiance para a simulação de iluminação natural do algoritmo de parametrização	257
Tabela 15 – Variáveis selecionadas para parametrização, suas respectivas quantidades e valores adotados	265
Tabela 16– Descrição dos vidros selecionados para a parametrização conforme relações entre T_{VIS} e FS.....	267
Tabela 17 – Propriedades térmicas adotadas para parametrização	270
Tabela 18– Valores dos parâmetros alterados para os casos do “conjunto nunca vistos”	273
Tabela 19 – Valores atribuídos às variáveis-chave para as simulações do zoneamento de iluminação natural para aberturas laterais	318
Tabela 20 – Parâmetros do Radiance para a simulação de iluminação natural para as simulações do zoneamento de iluminação natural	319
Tabela 21 – Resultados de R^2 e SQR para as etapas da adaptação da equação de Lynes para a substituição do $FLD_{médio}$ por DA_{alvo} nas equações dinâmicas	332

Tabela 22 – Resultados de R ² e SQR para as diferentes opções de equações testadas	334
Tabela 23 – Valores de índices de largura de zona para cada janela	338
Tabela 24 – Desempenho da RNA 9 para os conjuntos de treino teste e da janela	342
Tabela 25 – Dados de entrada utilizados para as equações da determinação da profundidade das zonas Z1 e Z2	343
Tabela 26 – Dados de entrada utilizados para as equações da determinação da largura das zonas Z1 e Z2	344
Tabela 27 – Dado de entrada utilizado na RNA para obtenção da DPU.....	346
Tabela 28 – Resultados da ponderação das DPUs pelas respectivas áreas das zonas	347
Tabela 29 – Desempenho das equações para 500 lux, PAF 80%, Zona Z1 e Zona Z2.....	348
Tabela 30 – DPU para a Zona Z1 prevista pela RNA 9 e simulada pelo plug-in DIVA pelo Grasshopper	350
Tabela 31 – Comparação da DPU prevista pelo método simplificado e simulada pelo <i>plug-in</i> DIVA, considerando todo o ambiente	351
Tabela 32 – DPU do ambiente prevista pelo método simplificado, considerando apenas a Zona Z1	351
Tabela 33 – Compilação das variáveis-chave testadas nas RNAs ao longo do trabalho	366
Tabela 34 – Valores padrão função <i>traingd</i>	455
Tabela 35 – Valores padrão função <i>trainbr</i>	456
Tabela 36 – Valores padrão função <i>trainlm</i>	457

LISTA DE QUADROS

Quadro 1 – Trabalhos encontrados na revisão de literatura sobre RNAs, agrupados por assunto de interesse deste trabalho (categorias) em ordem cronológica	95
Quadro 2 – Critérios adotados para a interrupção do treinamento da rede e sua respectiva justificativa.....	155
Quadro 3 – Critérios utilizados para a análise dos métodos simplificados	409
Quadro 4 – Hierarquia de características dos métodos simplificados consideradas como limitação	411
Quadro 5 – Classificação dos métodos simplificados levantados na bibliografia para a verificação da iluminação natural	413

LISTA DE EQUAÇÕES

Equação 1 – função soma	75
Equação 2 – função limiar	75
Equação 3 – função linear por partes	76
Equação 4 – função sigmoide	76
Equação 5 – saída do neurônio	76
Equação 6 – Quantidade de neurônios na camada oculta de uma rede neural (Hecht-Nielsen, 1987)	82
Equação 7 – Quantidade de neurônios na camada oculta de uma rede neural (Upadhyaya-Eryurek, 1992)	83
Equação 8 – Quantidade de neurônios na camada oculta de uma rede neural (fóruns de discussão)	83
Equação 9 – Regra de atualização dos pesos sinápticos: Levenberg-Marquardt	86
Equação 10 – normalização dos dados entre 0 e 1	116
Equação 11 – normalização dos dados entre -1 e 1	116
Equação 12 – erro observado para um determinado período (e_t)	118
Equação 13 – erro absoluto (EA)	119
Equação 14 – erro absoluto médio (EAM)	119
Equação 15 – erro percentual (EP_t)	119
Equação 16 – erro percentual absoluto (EPA)	119
Equação 17 – erro percentual absoluto médio (EPAM)	120
Equação 18 – erro quadrático médio (EQM)	120
Equação 19 – erro quadrático médio normalizado (EQMN)	120
Equação 20 – Modelo de regressão linear multivariada	130
Equação 21 – Indicador de consumo com o uso da luz natural – $R^2 = 0,4922$. (Didoné, 2009)	131
Equação 22 – Indicador de consumo com o uso da luz natural – $R^2 = 0,6243$. (Didoné, 2009)	131
Equação 23 – Indicador de consumo com o uso da luz natural – $R^2 = 0,8028$. (Didoné, 2009)	132
Equação 24 – barreira do quartil inferior (Q_{25})	156
Equação 25 – barreira do quartil superior (Q_{75})	156
Equação 26 – índices de ambiente K	271
Equação 27 – Fator de Luz Diurna Médio	314
Equação 28 – fórmula de limite de profundidade de Lynes (CIBSE, 1999)	315
Equação 29 – Modelo de regressão função PROJ.LOG	320
Equação 30 – profundidade da zona com base na área de todas as superfícies internas de um paralelepípedo retângulo	322

Equação 31 – largura da zona para cada lado a partir da aresta da janela	338
Equação 32 – área da Zona Z1 - EQUAÇÃO VIII – Conjunto 500 lux separado por PAF: PAF 80%	343
Equação 33 – área da Zona Z2 (Z1+Z2) - EQUAÇÃO XII – Conjunto 500 lux separado por PAF: PAF 80	343
Equação 34 – Pontuação Final do RTQ-C	353
Equação 35 – Z2 (Z1+Z2) - EQUAÇÃO I - Todos os modelos (300 lux e 500 lux)	446
Equação 36 – Z2 (Z1+Z2) - EQUAÇÃO II - Excluindo os modelos com PAF 80% (300 lux e 500 lux)	446
Equação 37 – Z2 (Z1+Z2) - EQUAÇÃO III - Separando o conjunto anterior – 300 lux	446
Equação 38 – Z2 (Z1+Z2) - EQUAÇÃO IV - Separando o conjunto anterior – 500 lux	447
Equação 39 – Z2 (Z1+Z2) - EQUAÇÃO V - Conjunto 300 lux separado por PAF: PAF 20%	447
Equação 40 – Z2 (Z1+Z2) - EQUAÇÃO VI - Z2 (Z1+Z2) - Conjunto 300 lux separado por PAF: PAF 40%	447
Equação 41 – Z2 (Z1+Z2) - EQUAÇÃO VII - Conjunto 300 lux separado por PAF: PAF 60%	447
Equação 42 – Z2 (Z1+Z2) - EQUAÇÃO VIII - Conjunto 300 lux separado por PAF: PAF 80%	448
Equação 43 – Z2 (Z1+Z2) - EQUAÇÃO IX - Conjunto 500 lux separado por PAF: PAF 20%	448
Equação 44 – Z2 (Z1+Z2) - EQUAÇÃO X - Conjunto 500 lux separado por PAF: PAF 40%	448
Equação 45 – Z2 (Z1+Z2) - EQUAÇÃO XI - Conjunto 500 lux separado por PAF: PAF 60%	449
Equação 46 – Z2 (Z1+Z2) - EQUAÇÃO XIII - Conjunto 300 lux, PAF 20% – separado por orientação: Norte	449
Equação 47 – Z2 (Z1+Z2) - EQUAÇÃO XIV - Conjunto 300 lux, PAF 20% – separado por orientação: Sul	449
Equação 48 – Z2 (Z1+Z2) - EQUAÇÃO XV - Conjunto 300 lux, PAF 20% – separado por orientação: Leste	450
Equação 49 – Z2 (Z1+Z2) - EQUAÇÃO XVI - Conjunto 300 lux, PAF 20% – separado por orientação: Oeste	450
Equação 50 – Z1 - EQUAÇÃO I –Conjunto 300 lux separado por PAF: PAF 20%	450
Equação 51 – Z1 - EQUAÇÃO II –Conjunto 300 lux separado por PAF: PAF 40%	451
Equação 52 – Z1 - EQUAÇÃO III –Conjunto 300 lux separado por PAF: PAF 60%	451

Equação 53 – Z1 - EQUAÇÃO IV –Conjunto 300 lux separado por PAF: PAF 80%	451
Equação 54 – Z1 - EQUAÇÃO V –Conjunto 500 lux separado por PAF: PAF 20%	452
Equação 55 – Z1 - EQUAÇÃO VI – Conjunto 500 lux separado por PAF: PAF 40%	452
Equação 56 – Z1 - EQUAÇÃO VII –Conjunto 500 lux separado por PAF: PAF 60%	452

LISTA DE ABREVIATURAS E SIGLAS

AHS	– Ângulo Horizontal de Sombreamento
ALH	– Amostragem por Hipercubo Latino
ANFIS	– Sistema de Inferência Neuro-Fuzzy Adaptativo (<i>Adaptive Neuro-Fuzzy Inference System</i>)
Apt	– Área do Plano de Trabalho
ASE	– Exposição anual à luz do sol (<i>Annual Sunlight Exposure</i>)
AVS	– Ângulo Vertical de Sombreamento
CC	– Componente Celeste
CIE	– <i>Commission Internationale de l'Eclairage</i>
CRE	– Componente Refletida Externa
CRI	– Componente Refletida Interna
DA	– Autonomia da Luz Natural (<i>Daylight Autonomy</i>)
DAcon	– Autonomia da Luz Natural – Limite Contínuo (<i>Continuous Daylight Autonomy</i>)
DAmáx	– Autonomia da Luz Natural – Limite Máximo (<i>Maximum Daylight Autonomy</i>)
DCI	– Densidade de Carga Térmica Interna
DPI	– Densidade de Potência Instalada
DPU	– Densidade de Potência Instalada em Uso
EA	– Erro Absoluto
EAM	– Erro Absoluto Médio (<i>Mean Absolute Error – MAE</i>)
EPA	– Erro Absoluto Percentual
EPAM	– Erro Absoluto Percentual Médio (<i>Mean Absolute Percentage Error – MAPE</i>)
EQM	– Erro Quadrático Médio (Root Mean Square Error – RMSE)

EQMN	– Erro Quadrático Médio Normalizado (<i>Normalized Root Mean Square Error – NRMSE</i>)
FLD	– Fator de Luz Diurna (<i>Daylight Factor – DF</i>)
FS	– Fator Solar
IEA	– <i>International Energy Agency</i>
NARX	– Nonlinear Autoregressive Network With Exogenous Inputs (<i>Nonlinear Autoregressive Network With Exogenous Inputs</i>)
PAF	– Percentual de Abertura na Fachada
PAP	– Percentual de Abertura por Área de Piso
PMC	– Perceptron Multicamadas (<i>Multilayer Perceptron – MLP</i>)
RNA	– Rede Neural Artificial
RTQ-C	– Regulamento Técnico da Qualidade para o Nível de Eficiência Energética de Edifícios Comerciais, de Serviços e Públicos
sDA	– Autonomia da Luz Natural Espacial (<i>Spatial Daylight Autonomy</i>)
sUDI	– Iluminâncias Úteis Espaciais (<i>Spatial Useful Daylight Illuminances</i>)
TRY	– Ano Climático de Referência (<i>Test Reference Year</i>)
T _{vis}	– Transmissão Visível
UDI	– Iluminâncias Úteis (<i>Useful Daylight Illuminances</i>)

SUMÁRIO

1.	INTRODUÇÃO	39
1.1	JUSTIFICATIVA	39
1.2	OBJETIVOS	45
1.2.1	OBJETIVO GERAL	45
1.2.2	OBJETIVOS ESPECÍFICOS	45
1.3	ESTRUTURA DA TESE	46
2.	REVISÃO BIBLIOGRÁFICA	49
2.1	ILUMINAÇÃO NATURAL	49
2.1.1	MEDIDAS PARA AVALIAÇÃO DE ILUMINAÇÃO NATURAL	57
2.1.2	SIMULAÇÃO COMPUTACIONAL	63
2.2	MÉTODOS SIMPLIFICADOS PARA AVALIAÇÃO DE ILUMINAÇÃO NATURAL NO AMBIENTE INTERNO	67
2.3	FUNDAMENTAÇÃO TEÓRICA: REDES NEURAIS ARTIFICIAIS	72
2.3.1	O NEURÔNIO ARTIFICIAL	73
2.3.2	A ARQUITETURA DA REDE	77
2.3.3	REDES <i>PERCEPTRON</i> MULTICAMADAS	79
2.3.4	PROCESSOS DE APRENDIZAGEM	80
2.3.5	DEFINIÇÃO DAS CAMADAS INTERMEDIÁRIAS	81
2.3.6	ALGORITMO DA RETROPROPAGAÇÃO DO ERRO (<i>BACKPROPAGATION</i>)	83
2.3.6.1	<i>Gradiente Descendente</i>	84
2.3.6.2	<i>Levenberg-Marquardt</i>	85
2.3.6.3	<i>Regularização bayesiana</i>	86
2.3.7	PANORAMA DO USO DE RNAs APLICADAS PARA A MODELAGEM DO COMPORTAMENTO ENERGÉTICO DE EDIFÍCIOS	87
2.3.7.1	<i>Conceito de modelo “caixa-preta”</i>	88
2.3.7.2	<i>Aplicação de RNA para a modelagem do desempenho energético em edificações</i>	88
2.3.7.3	<i>Aplicação de RNA para prever o consumo de energia elétrica em edifícios iluminados naturalmente</i>	97
2.4	CONSIDERAÇÕES FINAIS DO CAPÍTULO DE REVISÃO BIBLIOGRÁFICA	98
3.	MÉTODO	101
3.1	ABORDAGEM SISTEMÁTICA DA PESQUISA	101
3.2	DEFINIÇÃO DAS PERGUNTAS ESTRUTURAIS DE PESQUISA (ETAPA 1)	105

3.3	IDENTIFICAÇÃO DAS POSSÍVEIS LIMITAÇÕES DA APLICAÇÃO DE RNAs PARA MODELAGEM DA ILUMINAÇÃO NATURAL (ETAPA 2)	105
3.3.1	DEFINIÇÃO DAS VARIÁVEIS-CHAVE DA ILUMINAÇÃO NATURAL PARA A EFICIÊNCIA ENERGÉTICA	106
3.3.2	IDENTIFICAÇÃO DOS PONTOS CRÍTICOS DA ARQUITETURA E DA CONFIGURAÇÃO DAS RNAs PARA O SEU DESEMPENHO	106
3.4	DEFINIÇÃO DAS AÇÕES REALIZADAS PARA RESPONDER ÀS PERGUNTAS DE PESQUISA (ETAPA 3)	107
3.4.1	PARAMETRIZAÇÃO E AMOSTRAGEM DO CONJUNTO	107
3.4.2	SIMULAÇÃO ENERGÉTICA COMPUTACIONAL	110
3.4.3	GERAÇÃO DOS METAMODELOS E ANÁLISE DE DESEMPENHO	112
3.5	CONSIDERAÇÕES FINAIS SOBRE O CAPÍTULO	122

4. POTENCIAL DAS RNAs PARA A MODELAGEM DO CONSUMO ENERGÉTICO CONSIDERANDO A ILUMINAÇÃO NATURAL **125**

4.1	INTRODUÇÃO	125
4.2	DETALHAMENTO DO MÉTODO	126
4.2.1	DESCRIÇÃO DA BASE DE DADOS DE DIDONÉ (2009)	127
4.2.1.1	<i>A Regressão Linear Multivariada de Didoné (2009)</i>	130
4.2.1.2	<i>Proposta de Equação Linear Multivariada por Didoné (2009)</i>	130
4.2.2	APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS	132
4.2.3	POTENCIAL DE GENERALIZAÇÃO PARA NOVOS CASOS	134
4.3	RESULTADOS	135
4.3.1	REDES NEURAIS ARTIFICIAIS PARA O CONJUNTO DE DIDONÉ (2009)	135
4.3.2	COMPARAÇÕES ENTRE OS MODELOS DE REGRESSÃO	137
4.3.3	POTENCIAL DE GENERALIZAÇÃO PARA NOVOS CASOS	137
4.4	CONSIDERAÇÕES FINAIS SOBRE O CAPÍTULO	143

5. INVESTIGAÇÃO SISTEMÁTICA DAS POTENCIALIDADES E DAS LIMITAÇÕES DAS RNAs – PARÂMETROS DO EDIFÍCIO **147**

5.1	INTRODUÇÃO	147
5.2	DETALHAMENTO DO MÉTODO	147
5.2.1	ESCOLHA DAS VARIÁVEIS-CHAVE	152
5.2.2	COMPARAÇÃO ENTRE AS CONFIGURAÇÕES DE RNA	152
5.2.3	EXPERIMENTAÇÃO DE PARÂMETROS DE ENTRADA E PARÂMETROS DE SAÍDA DA REDE	153

5.2.4	ALTERAÇÃO DA ARQUITETURA E PARÂMETROS DE TREINAMENTO DA REDE	154
5.2.5	INVESTIGAÇÃO DA VARIÁVEL ORIENTAÇÃO	156
5.2.6	EXPLORAÇÃO: TIPOS DE VARIÁVEIS-CHAVE <i>VERSUS</i> QUANTIDADE DE PARÂMETROS DE ENTRADA	159
5.2.7	REFINAMENTOS DOS TÓPICOS ANTERIORES	160
5.3	RESULTADOS	161
5.3.1	ESCOLHA DAS VARIÁVEIS-CHAVE	161
5.3.2	COMPARAÇÃO ENTRE AS CONFIGURAÇÕES DE RNA	162
5.3.3	EXPERIMENTAÇÃO DE PARÂMETROS DE ENTRADA E PARÂMETROS DE SAÍDA DA REDE	166
5.3.3.1	<i>Resultados da ação 1 – a inclusão dos parâmetros de saída: Ventiladores</i>	167
5.3.3.2	<i>Resultados da ação 2 – o agrupamento das variáveis-chave primárias PAF e T_{VIS} (Abertura Efetiva)</i>	168
5.3.3.3	<i>Resultados da ação 3 – a adição de parâmetros de saída (suficiência da iluminação natural)</i>	170
5.3.4	ALTERAÇÃO DA ARQUITETURA E PARÂMETROS DE TREINAMENTO DA REDE	172
5.3.4.1	<i>Resultados da ação 1 – avaliação dos critérios de parada do treinamento da rede</i>	172
5.3.4.2	<i>Resultados da ação 2 – testes com diferentes quantidades de camadas intermediárias</i>	174
5.3.4.3	<i>Resultados da ação 3 – teste com o número de neurônios na camada intermediária</i>	176
5.3.5	INVESTIGAÇÃO DA VARIÁVEL ORIENTAÇÃO	179
5.3.5.1	<i>Resultados da ação 1 – análise da codificação de entrada de orientação</i>	179
5.3.5.2	<i>Resultados da ação 2 – análise da influência do aumento de padrões no conjunto de treinamento</i>	181
5.3.5.3	<i>Resultados da ação 3 – análise dos efeitos do parâmetro Orientação com relação às outras variáveis-chave</i>	183
5.3.6	INVESTIGAÇÃO DAS VARIÁVEIS PAF E T_{VIS}	188
5.3.6.1	<i>Resultados da ação 1 – análise da influência do aumento de padrões no conjunto de treinamento para PAF e T_{VIS}</i>	188
5.3.6.2	<i>Resultados da ação 2 – análise da influência do aumento de padrões direcionados à ocorrência dos maiores erros</i>	198
5.3.7	REFINAMENTOS DOS TÓPICOS ANTERIORES	202
5.3.7.1	<i>Resultados da ação 1 – inclusão do parâmetro fator solar (FS)</i>	202
5.3.7.2	<i>Resultados da ação 2 – isolamento de cada um dos parâmetros de saída em redes individuais</i>	205
5.3.7.3	<i>Resultados da ação 3 – proposição de redes neurais individuais para cada orientação</i>	206

5.3.7.4	<i>Resultados da ação 4 – refinamento do número de neurônios na camada interna e do algoritmo de otimização</i>	207
5.4	CONSIDERAÇÕES FINAIS SOBRE O CAPÍTULO	209

6. INVESTIGAÇÃO SISTEMÁTICA DAS POSSIBILIDADES E DAS LIMITAÇÕES DAS RNAs – CONTEXTO DO EDIFÍCIO **213**

6.1	INTRODUÇÃO	213
6.2	DETALHAMENTO DO MÉTODO	213
6.2.1	ESCOLHA DAS VARIÁVEIS-CHAVE	216
6.2.2	AGRUPAMENTO DE PARÂMETROS DE ENTRADA	217
6.2.3	AGRUPAMENTOS DE LOCALIDADE REFERENTES A DIFERENTES HEMISFÉRIOS	218
6.2.4	LIMITES ADOTADOS PARA OS PARÂMETROS DE ENTRADA PARA O TREINAMENTO DA REDE	218
6.2.5	VARIÁVEIS PARA DESCREVER CARACTERÍSTICAS CLIMÁTICAS E DE DISPONIBILIDADE DE LUZ	219
6.2.6	VALIDAÇÃO DO MÉTODO DE TESTE DE METAMODELOS BASEADOS EM SIMULAÇÕES ENERGÉTICAS PARAMÉTRICAS	219
6.3	RESULTADOS	220
6.3.1	ESCOLHA DAS VARIÁVEIS-CHAVE	220
6.3.2	AGRUPAMENTO DE PARÂMETROS DE ENTRADA	222
6.3.2.1	<i>Resultados da ação 1 – teste do algoritmo</i>	222
6.3.2.2	<i>Resultados da ação 2 – teste da quantidade de neurônios na camada intermediária</i>	227
6.3.2.3	<i>Resultados da ação 3 – teste de agrupamentos dos padrões de entrada da rede</i>	229
6.3.2.4	<i>Resultados da ação 4 – teste do ajuste de neurônios para os agrupamentos de parâmetros de entrada da rede</i>	232
6.3.3	AGRUPAMENTOS DE LOCALIDADE REFERENTES A DIFERENTES HEMISFÉRIOS	233
6.3.4	LIMITES ADOTADOS PARA OS PARÂMETROS DE ENTRADA PARA O TREINAMENTO DA REDE	235
6.3.4.1	<i>Resultados da ação 1 – avaliação dos limites dos parâmetros de entrada nos conjuntos de treinamento e teste</i>	235
6.3.4.2	<i>Resultados das ações 2 – ajuste das cidades nos conjuntos – e 3 – novo teste do agrupamento de Hemisférios</i>	237
6.3.5	VARIÁVEIS PARA DESCREVER CARACTERÍSTICAS CLIMÁTICAS E DE DISPONIBILIDADE DE LUZ	239
6.3.5.1	<i>Resultados da ação 1 – substituição das variáveis térmicas</i>	239
6.3.5.2	<i>Resultados da ação 2 – complementação das variáveis da disponibilidade de luz</i>	242

6.3.6	VALIDAÇÃO DO MÉTODO DE TESTE DE METAMODELOS BASEADOS EM SIMULAÇÕES ENERGÉTICAS PARAMÉTRICAS	245
6.4	CONSIDERAÇÕES FINAIS SOBRE O CAPÍTULO	247
7.	<u>INVESTIGAÇÃO SISTEMÁTICA DAS POTENCIALIDADES E DAS LIMITAÇÕES DAS RNAs – DESEMPENHO DO EDIFÍCIO</u>	251
7.1	INTRODUÇÃO	251
7.2	DETALHAMENTO DO MÉTODO	251
7.2.1	ESCOLHA DAS VARIÁVEIS-CHAVE	256
7.2.2	PARAMETRIZAÇÃO DOS MODELOS E SIMULAÇÃO INTEGRADA DE ILUMINAÇÃO NATURAL E ENERGIA	257
7.2.3	AMOSTRAGEM POR HIPERCUBO LATINO	258
7.2.4	TESTES DO DESEMPENHO DOS DIFERENTES TAMANHOS DE AMOSTRAS PARA A MODELAGEM DOS PARÂMETROS DE DESEMPENHO ATRAVÉS DAS RNAs	260
7.2.5	INVESTIGAÇÃO DOS AGRUPAMENTOS DOS PARÂMETROS DE DESEMPENHO DIANTE DE VARIAÇÕES PARAMÉTRICAS DE VARIÁVEIS DA DESCRIÇÃO DO EDIFÍCIO	261
7.2.6	INVESTIGAÇÃO SOBRE O EFEITO DA INCLUSÃO DE VARIÁVEIS DO CONTEXTO DO EDIFÍCIO PARA OS DIFERENTES PARÂMETROS DE DESEMPENHO	262
7.3	RESULTADOS	263
7.3.1	ESCOLHA DAS VARIÁVEIS-CHAVE	263
7.3.2	PARAMETRIZAÇÃO DOS MODELOS E SIMULAÇÃO INTEGRADA DE ILUMINAÇÃO NATURAL E ENERGIA	273
7.3.2.1	<i>Resultados da ação 1 – validação Viper Grasshopper/DIVA/Daysim-EnergyPlus</i>	274
7.3.2.2	<i>Resultados da ação 2 – o conceito do algoritmo</i>	274
7.3.3	AMOSTRAGEM POR HIPERCUBO LATINO	276
7.3.4	TESTES DO DESEMPENHO DOS DIFERENTES TAMANHOS DE AMOSTRAS PARA A MODELAGEM DOS PARÂMETROS DE DESEMPENHO ATRAVÉS DAS RNAs	278
7.3.4.1	<i>Resultados da ação 1 – teste de normalidade das amostras</i>	278
7.3.4.2	<i>Resultados da ação 2 – teste da quantidade de neurônios na camada intermediária</i>	279
7.3.4.3	<i>Resultados da ação 3 – teste do algoritmo</i>	281
7.3.4.4	<i>Resultados da ação 4 – teste do agrupamento de parâmetros de desempenho</i>	281
7.3.5	INVESTIGAÇÃO DOS AGRUPAMENTOS DOS PARÂMETROS DE DESEMPENHO DIANTE DE VARIAÇÕES PARAMÉTRICAS DE CARACTERÍSTICAS DA DESCRIÇÃO DO EDIFÍCIO	286

7.3.5.1	<i>Resultados da ação 1 – teste do agrupamento de parâmetros de desempenho</i>	286
7.3.5.2	<i>Resultados da ação 2 – ajuste do número de neurônios</i>	289
7.3.5.3	<i>Resultados da ação 3 – comparação entre os resultados adotando as duas abordagens de teste da rede: “nunca vistos” e literatura</i>	292
7.3.6	INVESTIGAÇÃO SOBRE O EFEITO DA INCLUSÃO DE VARIÁVEIS DO CONTEXTO DO EDIFÍCIO PARA OS DIFERENTES PARÂMETROS DE DESEMPENHO	296
7.4	CONSIDERAÇÕES FINAIS SOBRE O CAPÍTULO	307

8. EXEMPLO DE APLICAÇÃO DE RNA PARA MÉTODO SIMPLIFICADO DE PREVISÃO DE ILUMINAÇÃO NATURAL **311**

8.1	INTRODUÇÃO	311
8.2	DETALHAMENTO DO MÉTODO	312
8.2.1	ZONEAMENTO DE ILUMINAÇÃO LATERAL	314
8.2.1.1	<i>Definição das variáveis-chave de iluminação natural</i>	316
8.2.1.2	<i>Simulação da iluminação natural</i>	318
8.2.1.3	<i>Proposição de equações dinâmicas para o cálculo da área das zonas</i>	319
8.2.2	PROPOSIÇÃO DO USO DA RNA PARA PREVISÃO DA DPU PARA FLORIANÓPOLIS	323
8.3	RESULTADOS	324
8.3.1	ZONEAMENTO DE ILUMINAÇÃO LATERAL	324
8.3.1.1	<i>Equações dinâmicas para a definição da profundidade das zonas</i>	324
8.3.1.2	<i>Formulação analítica para a definição da largura das zonas</i>	335
8.3.2	PROPOSIÇÃO DO USO DA RNA PARA PREVISÃO DA DPU PARA FLORIANÓPOLIS	338
8.3.2.1	<i>Resultado da RNA</i>	341
8.3.2.2	<i>Exemplo de aplicação do método para um ambiente com uma janela</i>	342
8.3.2.3	<i>Verificação do erro da proposta apresentada</i>	347
8.4	CONSIDERAÇÕES FINAIS SOBRE O CAPÍTULO	351

9. CONCLUSÃO **359**

9.1	CONCLUSÃO GERAL DO TRABALHO	359
9.2	CONCLUSÃO SOBRE AS VARIÁVEIS-CHAVE PARA A ILUMINAÇÃO NATURAL RELACIONADOS AO CONSUMO ENERGÉTICO DA EDIFICAÇÃO (1.º OBJETIVO ESPECÍFICO)	362

9.3	CONCLUSÃO SOBRE O POTENCIAL DAS REDES NEURAIAS ARTIFICIAIS DIANTE DA REGRESSÃO LINEAR MULTIVARIADA (2.º OBJETIVO ESPECÍFICO)	367
9.4	CONCLUSÃO SOBRE AS VARIÁVEIS DA DESCRIÇÃO DO EDIFÍCIO (3.º OBJETIVO ESPECÍFICO)	368
9.5	CONCLUSÃO SOBRE AS VARIÁVEIS DO CONTEXTO DO EDIFÍCIO (4.º OBJETIVO ESPECÍFICO)	369
9.6	CONCLUSÃO SOBRE AS VARIÁVEIS DO DESEMPENHO DO EDIFÍCIO (5.º OBJETIVO ESPECÍFICO)	371
9.7	CONCLUSÃO SOBRE A PROPOSIÇÃO DO MÉTODO SIMPLIFICADO	373
9.8	DESDOBRAMENTOS DO TRABALHO	373
9.9	LIMITAÇÕES DO TRABALHO	374
9.10	RECOMENDAÇÕES PARA TRABALHOS FUTUROS	375

REFERÊNCIAS **377**

GLOSSÁRIO **405**

APÊNDICE **407**

APÊNDICE A	– COMPILAÇÃO E ANÁLISE DO LEVANTAMENTO BIBLIOGRÁFICO SOBRE FERRAMENTAS SIMPLIFICADAS PARA ESTIMATIVA DE ILUMINAÇÃO NATURAL	407
APÊNDICE B	– RESUMO DAS FERRAMENTAS UTILIZADAS NESTE TRABALHO	419
Apêndice B1.	– <i>EnergyPlus</i> : simulação termoenergética	419
Apêndice B2.	– DIVA: Simulação integrada	420
Apêndice B3.	– Grasshopper – Parametrização	422
Apêndice B4.	– MATLAB	422
Apêndice B5.	– EasyNN-plus	423
APÊNDICE C	– GRÁFICOS DOS EPAMs PARA AS DIFERENTES CODIFICAÇÕES DA VARIÁVEL ORIENTAÇÃO	425
APÊNDICE D	– GRÁFICOS DOS EPAMs PARA AS DIFERENTES QUANTIDADES DE CASOS DE PAF E T_{vis}	431
APÊNDICE E	– TESTE DE NORMALIDADE DAS AMOSTRAS	437
APÊNDICE F	– EQUAÇÕES DA PROPOSTA DO ZONEAMENTO DE ILUMINAÇÃO NATURAL	445
APÊNDICE G	–MAPA-RESUMO DAS PERGUNTAS E DAS RESPOSTAS DA TESE	453

ANEXO **455**

1. INTRODUÇÃO

Neste capítulo são apresentados o tema desta tese, bem como sua justificativa, seus objetivos e a estrutura do documento.

1.1 JUSTIFICATIVA

Muitos estudos comprovaram a preferência dos usuários pela luz natural como fonte de luz em edificações (EDWARDS; TORCELLINI, 2002; MAYHOUB; CARTER, 2011). Além de apresentar melhor qualidade na reprodução das cores e conferir dinamismo aos ambientes, as aberturas utilizadas para captar a luz do dia possibilitam contato com o exterior. O seu adequado aproveitamento é uma estratégia fundamental para projetos de edifícios de alto desempenho. Heschong (2011) a descreve como uma estratégia *win-win*, pois, ao mesmo tempo em que possui grande potencial de partido projetual, possibilitando a criação de espaços emblemáticos, propicia ambientes luminosos de alta qualidade, reforçando o conforto e o bem-estar, requer baixa manutenção e apresenta potencial de economia de energia. Quanto ao bem-estar, destaca-se a relação com a saúde dos ocupantes, considerando-se os efeitos visuais e não visuais da luz, em especial pela sua influência no sistema endócrino, no ritmo circadiano e em aspectos psicológicos (REPPERT; WEAVER, 2002; CIE, 2003, 2009). Acrescenta-se ainda a relação do aumento da produtividade com espaços iluminados naturalmente (HESHONG, 2003b, c, a; LOFTNESS et al., 2008). Esse argumento merece destaque, visto que o custo homem/hora é um dos mais elevados em ambientes corporativos (LESLIE, 2003). O conceito de *Triple Bottom Line – TBL* (abordagem tripartida) comprova os benefícios financeiros do uso da iluminação natural sob os aspectos econômicos, ambientais e humanos, destacando os humanos como os de retorno financeiro mais rápido (LOFTNESS et al., 2014). Por fim, ressalta-se que a maior disponibilidade de iluminação natural coincide com o horário de funcionamento de grande parte das edificações comerciais, o que apresenta elevado potencial de economia de energia nessas edificações (WILLIAMS et al., 2012).

Para a obtenção de um espaço bem iluminado, a iluminação natural deve ser considerada um princípio organizador de projeto (PEREIRA et al., 2005). Reinhart e Wienold (2011) propõem uma definição híbrida para um espaço bem iluminado naturalmente, considerando-se elevada a satisfação dos ocupantes quanto ao conforto visual e térmico com baixo consumo energético para a iluminação

artificial, o aquecimento e o resfriamento. O aspecto energético chama atenção, visto que, segundo o Balanço Energético Nacional (EPE, 2014), as edificações são responsáveis por 48,53% do consumo de energia elétrica no país; percentual semelhante pode ser observado no consumo das edificações nos Estados Unidos e na Europa (BPIE, 2011; US-DOE, 2014). No Brasil, a falta de chuvas e a baixa do nível dos reservatórios das hidroelétricas, principal matriz energética, levaram à crise energética e ao risco de racionamento ocorridos no primeiro trimestre de 2014 e que se repetem em 2015, resultando, inclusive, no acionamento ininterrupto de termoelétricas. O alto custo financeiro e o ambiental dessas alternativas apontam mais uma vez para a necessidade de medidas de eficiência energética. Tais medidas normalmente são as opções mais econômicas de reduzir o consumo energético, o custo de operação da edificação e as emissões de carbono (KNEIFEL, 2011).

Muitos países têm adotado códigos, normas e certificações com o objetivo de melhorar o desempenho energético das edificações. No cenário nacional, em resposta ao racionamento de energia ocorrido em 2001, sancionou-se a primeira Lei de Eficiência Energética em Edificações: a Lei nº. 10.295, que dispõe sobre a Política Nacional de Conservação e Uso Racional de Energia (BRASIL, 2001b). Essa lei foi regulamentada pelo Decreto nº. 4.059, que estabeleceu a necessidade da criação de “[...] níveis máximos de consumo de energia, ou mínimos de eficiência energética, de máquinas e aparelhos consumidores de energia fabricados ou comercializados no país, bem como as edificações construídas” (BRASIL, 2001a).

Nesse contexto foi publicado em 2009 os Requisitos Técnicos da Qualidade para Edifícios Comerciais, de Serviços e Públicos (INMETRO, 2010) visando classificar o consumo de energia elétrica nas edificações. Esse regulamento vem passando por constantes atualizações, mas ainda considera os benefícios da iluminação natural de forma superficial. No cenário internacional, documentos normativos, bem como métodos de auxílio de projeto, quando consideram os efeitos da iluminação natural, fazem menção à integração da iluminação natural com a artificial através de sistemas de controles e manuais de boas práticas (ALMEIDA; MARTINS, 2014). Entretanto, normalmente, limitam-se ao aspecto lumínico e a algumas variáveis-chave da iluminação referentes à fachada, desconsiderando as relações no nível do ambiente.

A complexidade em quantificar o potencial de economia de energia através do aproveitamento da iluminação natural reside em impacto duplo: nos sistemas de iluminação artificial e condicionamento

de ar. As variações climáticas, sazonais e diárias da luz natural ainda devem ser combinadas com os componentes da edificação e, principalmente, as características das aberturas, pois terão impacto na transferência de calor radiante e condutivo. Avaliações energéticas que priorizam apenas o desempenho térmico de edificações condicionadas, para evitar ganhos de calor, limitam o tamanho das aberturas e incentivam o uso de vidros de baixo ganho de calor solar, que, em sua maior parte, possuem baixa transmissão de luz. Ao tratar as aberturas da mesma forma que as demais vedações do edifício, induz-se o projetista a crer que o melhor edifício seria aquele com o mínimo de aberturas, o que, de forma simplista, seria um edifício sem janelas (SAXENA, 2013).

Entretanto, ao aproveitar a iluminação natural de forma adequada, também são reduzidos os ganhos de calor interno, o balanço entre luz e calor advindos da abertura; trata-se, então, de um equacionamento complexo (PEREIRA, 1992) que também deve considerar o dinamismo do clima, da sazonalidade, do dia, da hora, da operação dos sistemas e da eficiência dos equipamentos (HESHONG, 2011). O grande desafio está em projetar e avaliar aberturas sob uma abordagem de componente dinâmico do envelope do edifício, considerando a avaliação de seus elementos de controle. Assim poderiam ser avaliadas de forma mais adequada sob seus impactos no conforto e no bem-estar humano, controlando os ganhos internos e maximizando o aproveitamento da iluminação natural (SAXENA, 2013).

No caso do Brasil, a condição climática é oportuna para esse balanço, visto que as condições de céu predominantes, em geral, apresentam alta disponibilidade de luz. Além disso, o maior consumo ocorre para resfriamento, que pode ser mitigado pela redução do calor gerado pelo sistema de iluminação artificial.

Ferramentas computacionais têm sido utilizadas para a modelagem do desempenho energético de edificações, tanto através de simulação termoenergética completa quanto de ferramentas simplificadas de auxílio ao projetista. Essas ferramentas devem oferecer subsídios aos projetistas para que esses possam, segundo o preceito “pensar e sentir enquanto agem/projetam”, tomar suas decisões de projeto (PAPAMICHAEL; PROTZEN, 1993).

As simulações termoenergéticas completas demandam elevado detalhamento e profissionais devidamente treinados para garantir a qualidade dos resultados. Um modelo de um ambiente simples retangular com apenas uma zona térmica necessita de mais de 200 informações no programa EnergyPlus, descontando-se as informações

para definir os parâmetros de saída. A simulação que modele adequadamente a iluminação natural é ainda mais demorada e complexa, além de demandar integração entre programas que simulem a iluminação natural anual e o comportamento térmico da edificação.

Métodos simplificados são importantes ferramentas para serem utilizadas, em especial, nas fases iniciais de projeto, em que as principais decisões estão sendo tomadas. Em contraste com a simulação computacional, propiciam respostas rápidas sem necessitar de significativo detalhamento de informações. Normalmente, são utilizados para comparar o desempenho de diferentes soluções de projeto, adotando como dados de entrada apenas variáveis-chave que afetam o fenômeno.

Embora exista uma grande quantidade de ferramentas simplificadas, poucas possibilitam a avaliação global do impacto da iluminação natural no consumo energético. Entende-se por global suas implicações no padrão de uso do sistema de iluminação artificial e de condicionamento de ar, o dinamismo do clima, bem como a influência da orientação e outras variáveis-chave arquitetônicas fundamentais para o fenômeno da luz.

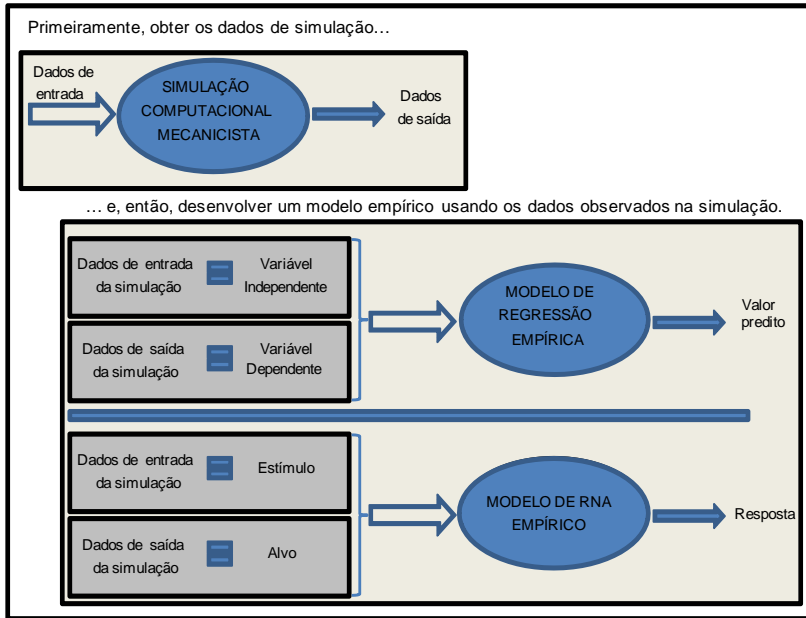
Os métodos simplificados que utilizam resultados pré-simulados, em sua maioria, baseiam-se somente em simulações termoenergéticas, utilizando o programa EnergyPlus, que apresenta conhecidas limitações, maximizando o potencial da iluminação natural em espaços distantes das aberturas (CSBR; LBNL, 2012; GIBSON, 2011; LI; WONG; CHEUNG, 2008; MOORE; CARTER; SLATER, 2004; MORET; NORO; PAPAMICHAEL, 2013; RAMOS; GHISI, 2010; WONG; WAN; LAM, 2010). Métodos estatísticos bastante difundidos, como a regressão linear multivariada (RLM), têm mostrado limitações na descrição da correlação entre dados de entrada e de saída de comportamento não linear (FOUCQUIER et al., 2013; JIMÉNEZ et al., 2013; KALOGIROU, 2001; MELO, 2012).

As redes neurais artificiais (RNAs) são técnicas computacionais de abordagem não linear, baseadas em modelos matemáticos que utilizam inteligência artificial e que, assim como os demais modelos, objetivam representar ou aproximar sistemas (HAYKIN, 2001; SILVA et al., 2004). Na maior parte dos casos, esses modelos se baseiam em observações e experimentos reais; entretanto, também podem ser utilizados como metamodelos, baseados em outros modelos, como a simulação computacional (BLANNING, 1975; MEISEL; COLLINS, 1973).

Segundo Wong, Wan e Lam (2010), as RNAs oferecem melhores respostas para edifícios com os padrões de utilização de energia não lineares, além de melhores correlações e menores erros para a aproximação de funções que outras técnicas como a RLM (BOCANEGRA, 2002). Entretanto, a RLM é um modelo cujas estruturas são ajustadas com base em informações conhecidas, já as RNAs não utilizam nenhuma informação conhecida previamente para a definição de sua estrutura (KILMER, 1994), o que as classifica como modelos “caixa-preta”.

Como vantagens das RNAs, salienta-se a necessidade de poucas informações iniciais e resposta instantânea, visto que se trata de metamodelagem de casos pré-simulados. O método apresenta como principal característica elevado poder de generalização e modelagem de funções não lineares. Na Figura 1 destaca-se a diferença entre a abordagem e terminologias adotadas na metamodelagem baseada em regressão e em RNAs. A simulação mecanicista ilustrada na Figura 1 utiliza modelos matemáticos baseados na observação do fenômeno físico que relaciona dados de entrada e dados de saída (ex.: programas de simulação energética). Na metamodelagem através de regressão empírica os pesos (constantes) atribuídos à variável independente para gerar a variável dependente são obtidos através de regressões com base em modelos estatísticos (ex.: RLM - a variação depende do efeito da inclusão de cada variável independente na variável dependente, se declive ou acréscimo). Para as RNAs, a geração destes pesos decorrentes das relações entre os estímulos para gerar os alvos, utiliza modelos computacionais, e se dá por meio de uma combinação não-linear destes estímulos. Os pesos são definidos através de ajustes sinápticos entre os neurônios e irão depender da arquitetura e das configurações de treinamento da rede (ex.: número de neurônios da rede e das condições iniciais do treinamento). O processo de ajustes sinápticos da rede é justamente o que a torna um modelo “caixa-preta”. Kilmer (1994) afirma que, para a aplicação de RNAs como metamodelos, é importante entender suas limitações e possibilidades para executar as tarefas elementares e fundamentais da simulação computacional, de forma a garantir a confiabilidade do modelo “caixa-preta”. Observou-se na literatura a carência de estudos que investigassem potencialidades para o uso desse método para modelar um fenômeno extremamente dinâmico como o da iluminação natural.

Figura 1 – Construção de metamodelos de simulação computacional



Fonte: Adaptado de: Kilmer (1994).

Os casos encontrados na bibliografia que empregam metamodelagem usando RNAs baseadas em simulação computacional termoenergética, em sua maioria, utilizam resultados fornecidos pelo agrupamento de cinco zonas térmicas com aberturas em todas as orientações. Essa solução não representa adequadamente o fenômeno da iluminação natural. As zonas térmicas nem sempre coincidem com as zonas de iluminação natural; e o agrupamento de zonas com aberturas em todas as orientações mitiga a influência de diferentes áreas de abertura orientadas para diferentes direções, fundamentais para a verificação da iluminação natural. Dessa forma, não se sabe o desempenho das redes neurais artificiais para modelar a influência dessas variáveis no consumo energético de edificações que aproveitam a luz natural. Outras variáveis, também de complexa modelagem, como o desempenho de edificações em diferentes localidades considerando o comportamento anual do clima, ainda merecem investigação. Os estudos encontrados, em sua maioria, consideram a edificação em apenas uma localidade, ou com variações climáticas diárias, ou por estações.

Diante do exposto, este trabalho buscou desenvolver uma investigação sobre as potencialidades da aplicação de redes neurais artificiais para estimar o potencial energético do aproveitamento da iluminação natural em edificações por meio da metamodelagem de suas principais variáveis-chave. A investigação se deu conforme questionamentos sob a ótica do projetista, focando nas variáveis-chave para a iluminação natural que influenciam o consumo energético de edificações não residenciais. Com isso, intencionou-se contribuir cientificamente para o aprofundamento do uso da metamodelagem estatística com base em RNAs, considerando as relações das variáveis-chave de iluminação natural. Dentre as várias formas de avaliar a qualidade da iluminação natural, este trabalho limitou-se aos aspectos energéticos e de suficiência de luz. Como contribuição social, espera-se somar no desenvolvimento de métodos com potencial para a proposição de ferramentas que auxiliem projetistas. O enfoque de Saxena (2013) descreve bem a intenção deste trabalho de adicionar a iluminação natural a avaliações energéticas de forma a colaborar com o desafio de não apenas tratar os edifícios como “máquinas energeticamente eficientes”, mas de produzir espaços para serem habitados: saudáveis, produtivos e aprazíveis para se trabalhar e viver.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Investigar as possibilidades e as limitações da aplicação de redes neurais artificiais para estimar o potencial energético do aproveitamento da iluminação natural em edificações não residenciais por meio da metamodelagem de suas variáveis-chave.

1.2.2 Objetivos específicos

Para alcançar o objetivo geral, foram elencados os seguintes objetivos específicos:

- identificar as variáveis-chave para a iluminação natural relacionadas ao consumo energético da edificação;
- verificar a aplicabilidade do uso de RNAs para a modelagem do consumo energético considerando a iluminação natural por meio de comparação com a técnica de modelagem estatística RLM;

- investigar como/se as RNAs podem representar variáveis da descrição do edifício que operam em diferentes escalas;
- explorar as potencialidades das RNAs para modelar o desempenho de edifícios localizados em diferentes climas com reduzido número de variáveis de entrada; e
- investigar a adequabilidade das RNAs para prever resultados do desempenho do edifício considerando variáveis de saída de diferentes naturezas – iluminação natural e consumo energético.

1.3 ESTRUTURA DA TESE

Este trabalho é composto de nove capítulos. O primeiro capítulo introduz o tema abordado de forma geral, justifica a relevância do estudo e destaca os objetivos a serem alcançados pela pesquisa. No segundo capítulo é apresentada a revisão de literatura sobre os principais temas abordados. Primeiramente, é exibido, de forma sucinta, um panorama geral da iluminação natural como elemento de economia de energia. Na segunda parte são apresentados métodos simplificados para a predição da iluminação natural, separados por categorias. A última parte trata da teoria das redes neurais artificiais abordadas no trabalho e o estado da arte da sua aplicação no contexto do consumo energético em edificações. Nesse capítulo são destacadas algumas lacunas na bibliografia que motivaram esta pesquisa.

O terceiro capítulo aborda o método geral utilizado na tese. Devido à abordagem sistemática adotada e às particularidades das investigações conduzidas no desenvolvimento da tese, os Capítulos 4 a 8 apresentam uma introdução, o detalhamento do método em que são descritas as ações do respectivo capítulo, os resultados e as considerações finais. O Capítulo 4 faz um paralelo entre um estudo previamente desenvolvido utilizando regressão linear multivariada para modelar a influência da luz natural no consumo energético de edificações comerciais e uma aplicação de redes neurais artificiais. Esse capítulo buscou avaliar o potencial do uso de RNAs diante da RLM, que é um método mais difundido.

Nos Capítulos 5 a 7 o estudo da aplicação de redes neurais é conduzido por meio de abordagens dos parâmetros do edifício, do contexto em que está inserido e do seu desempenho; todos baseados na seleção de variáveis-chave para a iluminação natural.

O Capítulo 8 diferencia-se dos demais ao apresentar um exemplo de aplicação de RNAs para a predição da Densidade de Potência em Uso (DPU – iluminação artificial acionada em função da disponibilidade de iluminação natural). Nesse capítulo propõe-se uma aplicação da DPU com um zoneamento de iluminação natural dinâmico como método simplificado para determinar o potencial de aproveitamento de iluminação natural para diferentes soluções de projeto considerando as condições dinâmicas de céu.

O Capítulo 9 apresenta uma síntese das conclusões do trabalho, destacando os desdobramentos da pesquisa, as limitações do trabalho e algumas sugestões para trabalhos futuros.

A Figura 2 mostra o mapa conceitual da presente proposta de tese. Nessa figura são destacadas as três perguntas-base para a estruturação da tese, iniciando-se por ilustrar o que será feito a partir da apresentação da pergunta original de pesquisa. Segue-se ilustrando o porquê da realização do trabalho e a indicação de como esse será feito, elencando os tópicos que serão abordados no método. Por fim, ilustra-se que será apresentado um exemplo de aplicação como produto final da tese.

Figura 2 – Mapa conceitual da tese



2. REVISÃO BIBLIOGRÁFICA

O presente capítulo aborda o estado da arte dos temas que norteiam este trabalho. Primeiramente, é apresentada uma breve revisão do potencial de economia de energia mediante o aproveitamento da luz natural. Em seguida, são discutidos os métodos simplificados propostos para esse fim. Na terceira parte deste capítulo é apresentado um panorama das pesquisas envolvendo redes neurais artificiais relacionadas com o consumo energético em edificações.

2.1 ILUMINAÇÃO NATURAL

No campo da arquitetura, a relação com a luz natural, mais do que uma necessidade psicológica e simbólica, está quase sempre ligada à origem das escolhas, conscientes ou inconscientes, da composição formal (RUGGIERO; FLORENSA; DIMUNDO, 2009). Entretanto, Assaf e Pereira (2003) afirmam que a técnica de produzir iluminação tem sido baseada exclusivamente nos efeitos visuais, sem considerar a sua influência como reguladora neurobiológica e os efeitos não visuais.

Nos dias de hoje, as pessoas passam grande parte do tempo dentro de edificações. Contudo, o ritmo circadiano humano baseia-se em uma evolução de milhões de anos em que o homem era exposto às condições de claridade e escuridão da natureza. Existem evidências de que o sistema não visual humano é mais sensível à região azul-verde do espectro da luz (distribuição espectral do céu azul) (CIE, 2003). No cerne da regulação do ritmo circadiano está uma complexa estrutura molecular cerebral acionada conforme a quantidade de luz natural que recebe. A desordem desse sistema pode ter implicações genéticas, fisiológicas e psicológicas (REPPERT; WEAVER, 2002). A produção de melatonina está diretamente ligada a essa alternância de luz e escuridão, sendo responsável pelo ajuste do sistema circadiano, da pressão sanguínea, da reprodução, do sistema imunológico, entre outros (ALTUN; UGUR-ALTUN, 2007). Young (2007) destacou o aumento da exposição a níveis elevados de luz para melhorar a produção de serotonina no cérebro. Esse neurotransmissor é influente no ritmo circadiano e fortemente responsável pelo bem-estar e por aspectos biopsíquicos.

No contexto da saúde, são relatados benefícios atribuídos à iluminação natural para a recuperação de pacientes em edificações hospitalares (BEAUCHEMIN; HAYS, 1996; CHOI; BELTRAN; KIM, 2012; WALCH et al., 2005). Esse aspecto pode ser estendido à

produtividade. Pesquisas relacionaram a iluminação natural e o contato com o exterior (paisagem) com a melhora do desempenho dos alunos em sala de aula (DEMIR; KONAN, 2013; HESHONG, 2003c). A iluminação natural também foi relacionada com a produtividade em escritórios (HESHONG, 2003b; LOFTNESS et al., 2008; MAYHOUB; CARTER, 2011) e com o aumento das vendas de 6% a 40%, conforme o aumento das horas de iluminação natural por ano (HESHONG, 2003a).

A luz do dia possibilita altos níveis de iluminâncias com uma composição espectral que garante melhor percepção das cores. Soma-se a isso o potencial de economia de energia através da complementação do sistema de iluminação artificial e da redução das cargas de resfriamento e aquecimento (AGHEMO; PELLEGRINO; LOVERSO, 2008). A maior disponibilidade de iluminação natural coincide com a demanda de pico dos edifícios comerciais: durante a tarde, em dias ensolarados (JARDIM et al., 2004). A demanda de energia pode ser mais onerosa que o custo da energia empregada, assim a redução da demanda de pico reduz a demanda por suprimentos de energia, que, muitas vezes, é atendida por fontes de energia com impacto ambiental (LESLIE, 2003), além de postergar a necessidade de ampliação da capacidade de geração, transmissão e distribuição de energia.

Sabe-se que os fatores determinantes para caracterizar a iluminação natural nos ambientes da edificação são o tamanho, a distribuição e a posição das aberturas; a profundidade e a forma dos ambientes; e as propriedades ópticas das superfícies. Segundo Pereira (1992), as aberturas são “olhos, ouvidos e pulmões” dos edifícios. Por natureza, apresentam dois grupos de parâmetros que podem ser classificados em físicos (iluminação natural, ventilação e calor) e psicológicos (acesso à luz natural, insolação e vistas para o exterior). O autor detecta como principal conflito na otimização das aberturas o acesso à iluminação natural *versus* o ganho de calor. A própria forma do edifício pode modificar a intensidade e a distribuição da iluminação natural, criando um ambiente luminoso apropriado. A luz direta pode ser filtrada através de *brises*, vegetação ou tratamentos nos vidros; e a luz difusa, captada e aproveitada para iluminação geral (LESLIE, 2003).

A admissão de luz e calor pelas aberturas apresenta impacto direto no consumo energético, em especial em edificações condicionadas. Assim, a proporção da área de abertura da fachada torna-se um parâmetro importante nesse balanço. Bodart e De Herd (2002) relacionaram o aumento da largura do ambiente com a redução do consumo em iluminação por m² de área de piso. Os autores fixaram a profundidade dos ambientes e alocaram um sensor centralizado,

consequentemente, com maior ângulo de céu visível para fachadas mais largas. Ghisi, Tinker e Ibrahim (2005) também observaram essa relação; entretanto, acrescentaram que essa premissa é válida para ambientes de mesma geometria. Quando a profundidade também é alterada, mesmo se mantendo a largura, o padrão de consumo pode ser modificado. Nesse estudo, que se baseou em simulações do VisualDOE, ambientes mais profundos apresentaram consumo energético menor para edificações condicionadas artificialmente e com integração entre os sistemas de iluminação natural e artificial. Os autores também relacionaram a área mínima da abertura recomendada para garantir vistas para o exterior com a área ideal para a eficiência energética. Esta última, na maioria dos casos, foi menor que a área mínima para a garantia de vistas para o exterior. Diante disso, recomendaram o aprofundamento em pesquisas sobre os parâmetros geométricos adotados para o cálculo da área que garante vistas para o exterior, visto que os atuais conflitam com a área ideal para a eficiência energética.

Essa relação é importante e complexa, visto que o conceito de contato visual com o exterior é relacionado à saúde e à produtividade, que são parâmetros economicamente ainda mais relevantes (HESHONG, 2003b; LESLIE, 2003; LOFTNESS et al., 2008; LOFTNESS et al., 2014); por outro lado, o consumo energético traz consigo o impacto ambiental da geração de energia (BRASIL, 2007; KNEIFEL, 2011). Ihm, Nemri e Krarti (2009) propuseram algumas relações geométricas para a avaliação do potencial de economia de energia através da iluminação natural: a área de janela pelo perímetro do ambiente como indicador do tamanho da janela relativo à área de planta iluminada; e a relação do perímetro pela área total para indicar a extensão da área iluminada com relação à área total da planta. Quanto mais próxima essa segunda relação for de 1, mais bem iluminado será o ambiente.

Além da geometria, o coeficiente de reflexão da luz das superfícies apresenta importante papel de distribuição e magnitude da luz (FONSECA, 2007). Com isso, influencia na redução do consumo de energia, comprovada por Bodart e De Herde (2002) ao identificarem que a diferença de consumo entre configurações de fachada e tamanho dos ambientes é maior para ambientes escuros.

As aberturas são responsáveis por grande parte do “dinamismo” das edificações. Ao observá-las apenas como combinações de vidro e esquadrias, ignora-se grande parte das soluções arquitetônicas que consideram dispositivos utilizados para melhorar seu desempenho e que apresentam papel fundamental no comportamento energético das

edificações (SAXENA, 2013). Esses dispositivos compreendem *brises* horizontais e/ou verticais (fixos ou móveis), marquises, prateleiras de luz e os próprios vidros, que, com suas propriedades ópticas, controlam a admissão de luz, além de englobarem componentes internos como persianas ou cortinas. Os elementos externos geralmente são mais eficientes no controle da luz solar direta e no ganho de calor do que dispositivos internos. Pereira (1992) comparou dados de iluminação e radiação obtidos através de simulação com modelos em escala e o modelo matemático para abertura lateral com *brises* externos especulares. Como resultado, confirmou o potencial desses dispositivos para melhorar a iluminação, com pequena penalização por ganho de calor. Em comparação com dispositivos difusores, a penalização variou entre 20 e 25%, enquanto a iluminação natural no fundo do ambiente melhorou 150%.

Contudo, os *brises* difusores também proporcionam melhora na magnitude e na distribuição do fluxo luminoso admitido, sendo os *brises* horizontais, por possuírem ângulo de corte vertical e assim recebendo mais luz, mais influentes na distribuição de luz que os verticais (BOGO, 2007). Mantendo-se o mascaramento do céu e alterando-se apenas a quantidade e a refletância das aletas, Fiuza (2008) chegou a observar 40% de diferença entre o fluxo luminoso admitido para as diferentes soluções avaliadas. Aghemo, Pellegrino e LoVerso (2008) avaliaram combinações de elementos de proteção solar quanto à quantidade de iluminação, penetração e uniformidade na seção do ambiente. *Brisés* e prateleira de luz externa com acabamentos especulares e semiespeculares foram os dispositivos com melhor desempenho. Não obstante, as superfícies especulares, quando iluminadas pela luz direta do sol, criaram altos níveis de iluminância, apresentando potencial para causar ofuscamento. Outras soluções como cobogós e muxarabis, devido a sua porosidade, possibilitam maior uniformidade na distribuição da iluminação que aberturas contínuas, favorecendo o conforto visual, evitando o ofuscamento (RUGGIERO; FLORENSA; DIMUNDO, 2009).

Os vidros também podem ser utilizados para favorecer o balanço luz *versus* calor através das propriedades transmissão visível (T_{VIS}) e fator solar (FS). Sob o aspecto da luz, aumentar a T_{VIS} possibilitará maior admissão da luz natural, conseqüentemente diminuirá a necessidade da complementação da iluminação artificial; entretanto, essa variação quanto ao consumo não é linear. Bodart e De Herde (2002) avaliaram nove tipos de vidro com T_{VIS} variando de 0 a 81% e iluminância-alvo de 500 lux através de simulação termoenergética.

Quando a luz natural supriu os 500 lux, o aumento na disponibilidade de iluminação (T_{VIS}) não apresentou mais influência no consumo de iluminação artificial, mas penalizou o sistema de condicionamento de ar. Kong, Li e Tsang (2008) levantaram características de 35 edifícios comerciais na China, sendo os vidros mais comuns o claro, o colorido, o reflexivo e o *low-e* com 5-6 mm de espessura. Dos 35 edifícios, apenas 11% utilizavam *low-e*, enquanto os outros apareceram na mesma proporção, aproximadamente 30%. Os vidros *low-e* possuem uma fina camada de óxido de metal que reduz substancialmente o ganho de calor sem reduzir a admissão de luz. Deve-se enfatizar que esse tipo de vidro é eficaz para minimizar o ganho de calor solar quando da incidência de ondas curtas. De todos os 35 edifícios, apenas dois possuíam vidro duplo. Fonseca et al. (2013) propuseram a avaliação do desempenho de vidros segundo o balanço luz *versus* calor, baseado no índice *Coolness* de Arasteh, Johnson e Selkowitz (1986), que relaciona FS e T_{VIS} considerando apenas a faixa visível do espectro e a medida Iluminâncias Úteis Espaciais (UDIs), limitando a faixa de iluminâncias úteis entre 300 lux e 2.000 lux. A combinação do índice com a medida de iluminação se mostrou útil ao oferecer informações térmicas e luminosas, além de indicar a possibilidade de ofuscamento através da proporção excedente de UDI máximo.

Dispositivos mais sofisticados, como fibra ótica, dutos de luz, iluminação integrada¹ e sistemas híbridos² de iluminação, foram desenvolvidos na tentativa de levar a iluminação natural em áreas distantes das aberturas; entretanto, esses sistemas ainda possuem um custo elevado e demandam uma análise de custo/benefício para serem implantados. Tanto a fibra ótica (GHISI; TINKER, 2004) quanto os sistemas híbridos (MAYHOUB; CARTER, 2010), apesar de proporcionarem economia de energia, ainda não configuram investimentos atrativos sob o ponto de vista energético.

A integração da iluminação artificial com a natural (ou vice-versa), para que seja considerada eficiente, deve satisfazer com qualidade as necessidades de quem vai exercer atividades no ambiente e também as necessidades de ambientação características de cada espaço, consumindo o mínimo de energia. Embora o sistema visual humano tenha grande capacidade de adaptação e possa funcionar mesmo com

¹ Sistemas que proporcionam luz natural e artificial separadamente, mas que são equipados com controle que maximiza a utilização da luz natural.

² Sistemas que combinam a iluminação natural e a artificial antes da distribuição da luz através da luminária.

quantidades mínimas de luz, se a iluminação não for considerada adequada, essa economia não pode ser vista como eficiência energética (ASSAF; PEREIRA, 2003).

As decisões críticas com relação ao aproveitamento da luz natural ocorrem na fase conceitual do projeto, quando as configurações do edifício e das esquadrias estão sendo feitas. Já as decisões mais relevantes para economizar energia em iluminação ocorrem na fase de projeto, especificação e comissionamento dos sistemas de controle de iluminação artificial (LESLIE, 2003). Entretanto, para uma boa integração, o sistema de iluminação artificial deve ser concebido de acordo com as distribuições da iluminação natural (MORAES; CLARO, 2014).

A eficiência energética de um sistema de iluminação pode ser definida como a capacidade de um sistema conversor transformar a energia elétrica em condições de visão, conforto e atmosfera visual (ASSAF; PEREIRA, 2003). Entendendo que a energia é função da potência e do tempo, reduzindo-se uma dessas duas variáveis, reduz-se o consumo energético. O aproveitamento da iluminação natural está diretamente relacionado à redução do tempo de acionamento da iluminação artificial.

A eficiência das instalações de iluminação artificial é mais fácil de ser mensurada que as de iluminação natural, pois se trata de um sistema estático. Embora haja discussões sobre a adequabilidade dos indicadores existentes em garantir um ambiente bem iluminado, essa limitação está mais relacionada com a dificuldade de definir e mensurar a qualidade da iluminação. Assaf e Pereira (2003) propõem um índice que relaciona a eficiência da lâmpada, do equipamento auxiliar, da luminária e do desenho da instalação e citam mais dois índices: Densidade de Potência de Iluminação, definido como a potência (W) por unidade de superfície do ambiente iluminado (m^2); e Potência Específica de Iluminação – Pei, que utiliza a densidade de potência de iluminação necessária para produzir uma iluminância horizontal de 100 lux por unidade de superfície ($W/m^2/100 \text{ lux}$). O primeiro é utilizado pelas normas americanas ASRHAE/IES 90.1 (ASHRAE, 2013) e TITLE 24 (CALIFORNIA ENERGY COMMISSION, 2013) e pelo regulamento brasileiro RTQ-C³ (INMETRO, 2010), já o segundo pelo código

3 O RTQ-C – Regulamento Técnico da Qualidade para o Nível de Eficiência Energética de Edifícios Comerciais, de Serviços e Públicos –, de abrangência nacional, foi publicado através da Portaria n. 163, de 8 de junho de 2009, como parte do Programa Brasileiro de Etiquetagem do Instituto Nacional de Metrologia,

britânico PART-L (EPBD-NCM, 2014). É importante notar que nenhum desses índices inclui a variável tempo de uso, a qual estaria relacionada à iluminação natural. Normalmente, esses índices são combinados com algumas considerações sobre sistemas de controles e zoneamento de iluminação natural.

Muitos autores já comprovaram o potencial de aproveitamento da iluminação para a conservação de energia em edifícios comerciais. Dentre os diferentes percentuais de economia relatados, a economia do sistema de iluminação artificial variou de 20% a 80% (BODART; DE HERDE, 2002; CARLO; PEREIRA; LAMBERTS, 2004; DIDONÉ; PEREIRA, 2010; DOULOS; TSANGRASSOULIS; TOPALIS, 2008; IHM; NEMRI; KRARTI, 2009; LI; TSANG, 2008; SOUZA, 2003; WILLIAMS et al., 2012). Já quanto ao consumo global, essa economia foi um pouco menor e variou entre 12 e 52% (BODART; DE HERDE, 2002; DIDONÉ; PEREIRA, 2010; LI; TSANG, 2008).

A razão para a redução do consumo do ar-condicionado refere-se basicamente à mitigação da carga térmica (aquecimento) gerada pelo sistema de iluminação artificial. Luminárias embutidas são responsáveis pela transferência de aproximadamente 50% de calor para a cavidade do teto, enquanto luminárias pendentes dissipam praticamente todo o calor gerado para o ambiente. As lâmpadas dissipam grande parte da energia em forma de calor radiante e, em menor grau, por convecção (MAYHOUB; CARTER, 2011).

Entre os sistemas de controle de iluminação artificial, estão o controle manual, o sensor de presença, o sensor por passos e os *dimmers*. O controle manual está diretamente ligado ao comportamento do usuário, se ativo ou passivo; o sensor de presença, a um padrão de ocupação; e os sensores *dimmers* e os por passos, com a iluminância mínima de projeto. Segundo Krarti, Erickson e Hillman (2005), o controle por passos pode ser uma alternativa mais barata que *dimmers*, mas pode criar problemas por desconforto visual. Um controle por passos varia a saída de luz e a entrada de energia elétrica das luminárias proporcionalmente. Em um sistema ideal dimerizável, a entrada de energia das luminárias é aproximada por uma função linear da saída de luz. Souza (2003) comparou controles liga/desliga, três passos e dimerizável; a estratégia três passos foi, em média, 9% mais eficiente

Qualidade e Tecnologia (INMETRO). Atualmente, a portaria vigente é a Portaria n. 372, de 17 de setembro de 2010, com três portarias complementares: Portaria n. 17, de 16 de janeiro de 2012; Portaria n. 299, de 19 de junho de 2013; e Portaria n. 126, de 18 de março de 2014.

que a liga/desliga, enquanto a dimerizável 15%. Quanto aos sistemas associados às zonas de iluminação, o sistema liga/desliga, quando utilizado em zonas próximo às janelas, pode proporcionar uma economia de energia bem próxima ao controle dimerizável. Já em zonas mais afastadas das aberturas, o sistema liga/desliga não traz bons resultados, sendo mais indicada a estratégia dimerizável. Como efeito do nível de iluminância-alvo no desempenho dos controles, quanto maior o nível de iluminância requerido, menor o potencial de economia de energia (IHM; NEMRI; KRARTI, 2009). Por fim, outra estratégia de controle é o uso da iluminação de tarefa. Essa estratégia permite uma iluminação geral mais baixa e viabiliza o controle da iluminação complementar pelo usuário, que pode ser ativo em relação à iluminação natural (RUBINSTEIN; ENSCOE, 2010).

Sistemas de controle normalmente refletem um custo inicial mais elevado ao empreendimento. Entretanto, esses custos podem ser abatidos em função da economia do condicionamento de ar e da iluminação artificial, além de possibilitarem a redução da quantidade de equipamentos instalados para a iluminação geral. Essas iniciativas também têm potencial social ao conscientizar o usuário da responsabilidade pelo sistema. O aproveitamento da luz refletida interna também pode favorecer a redução do dimensionamento do sistema de iluminação (USGBC, 2009).

Para a eficiência dos sistemas de controle, é importante que as zonas de controle sejam estabelecidas em consonância com as zonas em que a iluminação natural é acessível (LI; TSANG, 2008; MOURA et al., 2009; ROCHA; PEREIRA, 2014; SOUZA, 2003). Além disso, apresentam relação com o impacto das soluções arquitetônicas na iluminação. Ihm, Nemri e Krarti (2009) observaram que o controle por passos proporcionou menor economia para janelas baixas, mas maior economia para janelas altas em comparação com o *dimmer*.

Outros tipos de controle, como os sensores de ocupação, também proporcionam economia de energia, variando de 20% (ASSAF; PEREIRA, 2003; REINHART, 2004) a 40% (RUBINSTEIN; ENSCOE, 2010). Esses sensores são mais difíceis de serem modelados para estimativas de economia, pois dependem do usuário. Todo estudo que envolve o usuário é mais complexo e tende a ser mais impreciso; entretanto, sabe-se que a previsão da operação dos edifícios é um grande desafio para a área de eficiência energética. Hunt (1979; 1980) foi um dos precursores nesse sentido na área de iluminação, desenvolvendo modelos de frequência com que os usuários acionariam a iluminação artificial em função da insuficiência da natural.

Vinte anos mais tarde, Reinhart (2004) propôs o Lightswitch - 2002, um algoritmo que acrescenta à modelagem do acionamento da iluminação a operação de persianas. Implementado em programa computacional, permitiu observar uma variação na demanda anual de energia entre 10 e 39 kWh/m² ano para um sistema de iluminação para o controle manual de iluminação e persianas considerando diferentes tipos de usuário. Persianas automáticas operando em função da luz natural reduziram a demanda em 40%. Usando o mesmo algoritmo, Bourgeois, Reinhart e McDonald (2006) mostraram que usuários ativos podem reduzir o consumo energético em mais de 40% quando comparados com usuários passivos.

2.1.1 Medidas para avaliação de iluminação natural

Uma discussão ainda atual que permeia o meio científico e aplicado é a definição de medidas para a avaliação da iluminação natural (ENERGY DESIGN RESOURCES, 2008; ENLIGHTEN, 2008; GALATIOTO; BECCALI; MILONE, 2014; HESHONG, 2011; MARDALJEVIC; HESCHONG; LEE, 2009; MARDALJEVIC et al., 2012; SAXENA, 2014). Mardaljevic, Heshong e Lee (2009), em um artigo sobre o assunto, provocam a discussão com a seguinte pergunta: “A iluminação natural pode ser adequadamente representada apenas por uma medida?”. Os próprios autores respondem em uma linha que é consenso na bibliografia: a definição do que é “adequado” ainda é vaga, mas seria algo que envolve minimizar o desconforto visual e aumentar a acuidade visual. Em 2006, a IES formou um subcomitê para pesquisar novas medidas de iluminação natural e estudar medidas de suficiência de iluminação, excesso de iluminâncias, penetração solar, uniformidade de iluminação horária e visão de céu (HESHONG; SAXENA; HIGA, 2010).

As medidas baseadas em iluminâncias são as mais difundidas e utilizadas há quase um século para a avaliação do desempenho de iluminação natural em ambientes internos (REINHART; RAKHA; WEISSMAN, 2014). As mais antigas têm abordagem estática (data e horários fixos) ou avaliam um único ponto por vez, dificultando avaliações de variações ao longo do tempo. O método mais comum é o fator de luz diurna (FLD), que é definido como a relação entre a iluminância interna de um ponto no interior do ambiente e a iluminância horizontal externa desobstruída sob o céu nublado padrão CIE (MOORE, 1991; NABIL; MARDALJEVIC, 2006). Uma das limitações dessa medida é a dificuldade de testar o desempenho da iluminação para

diferentes orientações (REINHART; MARDALJEVIC; ROGERS, 2006). Baker e Steemers (2002) apresentaram um método que considera o efeito da orientação para o FLD baseado no parâmetro “fator de orientação”. Esse fator permite a verificação da assimetria do brilho do céu conforme a orientação. Alternativamente, são utilizados diagramas de trajetória do sol ou análise de sombreamento dinâmico para representar o comportamento da luz do sol, mas essas formas de análise não consideram a contribuição da luz do céu ou da parcela refletida da luz (MARDALJEVIC; HESCHONG; LEE, 2009). No Brasil, a norma NBR 15.215-3 descreve um procedimento de cálculo para a determinação da incidência de iluminação natural em um ponto num plano horizontal do ambiente interno, obtida através de aberturas da edificação. O método de cálculo utilizado é o método do fluxo dividido, cuja iluminância é obtida através do Diagrama de Contribuição Relativa da Luz – DCRL (ABNT, 2005a). Medidas estáticas de luminância também são utilizadas, em especial para avaliações de ofuscamento (LOVE, 1992), e ganharam força com a evolução das imagens HDR, que permitem a visualização de mapas de distribuição de iluminâncias de qualquer ângulo (PAPAMICHAEL; FERNANDES; TCHANAVHAREONKIT, 2010).

Com a evolução dos computadores e conseqüentemente da simulação computacional, na década passada surgiram as medidas dinâmicas, que fornecem séries anuais de iluminância. Essas medidas consideram a variação da luz natural segundo a latitude e a distribuição temporal ao longo do dia e do ano, considerando informações climáticas. Entre elas, estão

- o Percentual de Aproveitamento de Luz Natural (PALN): estima o potencial de economia de energia através do uso da luz natural, considerando três tipos de controle (liga/desliga, passo automático e *dimmer* automático). Para tal, o ambiente é dividido em zonas de iluminação com distribuição de iluminâncias similares. Considera três condições de céu (claro, parcial e encoberto), que são ponderadas por frequência de ocorrência (SOUZA, 2003);
- a Autonomia da Luz Natural (DA): é o percentual de horas ocupadas em que um nível mínimo de iluminância no plano de trabalho pode ser garantido apenas pela iluminação natural. Esta medida não identifica quando os níveis de iluminação são excessivos, impossibilitando a verificação de

- ocorrência de ofuscamento e do excesso de carga térmica admitida (REINHART; MORRISON, 2003);
- a Autonomia da Luz Natural – Limite Contínuo (DAcon): em contraste com o DA convencional, são atribuídos créditos parciais (proporcionais) para faixas de tempo ao longo do ano em que o nível de iluminâncias fica abaixo do nível mínimo de iluminação. Esta medida permite considerar a preferência do usuário, que é mais flexível que limites rígidos normativos (REINHART; MARDALJEVIC; ROGERS, 2006);
 - a Autonomia da Luz Natural – Limite Máximo (DAmáx): esta variação do DA considera o ofuscamento. Indica o percentual de horas ocupadas em que a luz direta do sol excede em 10 vezes a iluminação planejada para o plano de trabalho (ROGERS, 2006); e
 - as Iluminâncias Úteis (UDI): são preestabelecidas faixas de iluminâncias nas quais são determinados os níveis de iluminação muito baixos, úteis ou elevados e o seu percentual de frequência de ocorrência (NABIL; MARDALJEVIC, 2005; NABIL; MARDALJEVIC, 2006). São considerados níveis insuficientes de iluminação valores inferiores a 100 lux; a faixa útil compreende valores entre 100 e 2.000 lux; e a excessiva, acima de 2.000 lux.

Em 2012, a IESNA publicou um documento indicando o DA relacionado com a área e a Exposição Anual ao Sol (ASE) como métodos aprovados para a avaliação da iluminação natural. Nesse conceito, a Autonomia Espacial da Luz Natural – sDA (IES, 2012) refere-se à porcentagem de área que excede um valor mínimo de iluminação, no caso 300 lux, por determinado período de tempo, nesse caso 50% das horas de ocupação ao longo do ano (8h às 18h) – sDA_{300,50%}. Esses valores foram determinados com base em um estudo de campo envolvendo 61 edifícios (escolas, escritórios e bibliotecas), pesquisas com ocupantes e pareceres de especialistas em iluminação natural através de análise de correlação (HESHONG, 2011; SAXENA et al., 2010). Para contribuir com a definição de alvos quantitativos para a sDA, Reinhart, Rakha e Weissman (2014) identificaram a necessidade de testar a capacidade da medida de distinguir áreas naturalmente iluminadas de áreas em que a iluminação natural é insuficiente.

Portanto, conduziram um estudo em salas de aula envolvendo a percepção dos estudantes e uma simulação computacional. Onze escolas de arquitetura foram envolvidas, com a participação da UFSC (PEREIRA et al., 2012). A pesquisa confirmou a adequabilidade da $sDA_{300,50\%}$, mas sugeriu a combinação desse índice com informações de ofuscamento e contraste. Também foi proposta uma variação da $sDA_{300,50\%}$ para uma iluminância-alvo de 150 lux a fim de representar áreas com aproveitamento menor da luz natural, mas significativo.

O quadro apresentado na Figura 3, proposto no relatório final de Medidas de Iluminação Natural para o *PIER – California Energy Commission*, elenca uma gama de questões a serem consideradas em uma análise completa do desempenho da iluminação natural. Dentre suas finalidades, foi elaborado para auxiliar nas discussões do Comitê de Iluminação Natural com o intuito de evidenciar o tipo de informação necessária para cada propósito e estabelecer as prioridades para o desenvolvimento de ferramentas importantes para alcançar esses propósitos (HESHONG, 2011).

O quadro foi organizado inspirado em uma equação, com a igualdade composta de variáveis de (1) conforto humano e (2) impacto energético como primeiro membro (dados de saída) e parâmetros determinantes para o desempenho da iluminação natural como segundo membro. As categorias principais abordam (A) a descrição completa do espaço tridimensional, (B) a descrição das propriedades das aberturas, (C) dados climáticos locais, (D) o contexto exterior, (E) o comportamento do usuário e (F) interações com outros sistemas da edificação

Figura 3 – Quadro de análise de iluminação natural proposto pelo Comitê de Iluminação Natural da IES

1	2	A	B	C	D	E	F
Conforto Humano	Impactos energéticos	Descrição do Espaço	Descrição das Aberturas	Informações Climáticas	Contexto Exterior	Comportamento do usuário	Sistemas Energéticos do Edifício
Iluminância	Energia de Iluminação	Geometria	Janelas	Sol	Terreno	Atividade	Iluminação
Suficiência Uniformidade Gradientes Distribuição espacial	Carga total equiv. kWh anual kW máximo Perfis de carga	Caixas Ortogonais complexas Mobiliário Brise vertical e horizontal Esquadrias, grade Ângulos Curvas	Tamanho e localização TVIS Envidraçamento difuso Efeitos de enquadramento Dependência angular TVIS variáveis Envidraçamento de propriedades ópticas complexas BSDF dinâmico	Altitude Azimute Intensidade horária Ajustes do terreno	Refletância difusa Inclinação Múltiplas condições Refletância especular Variação sazonal Variação climática	Tipo de atividade Disposição do mobiliário Localização da atividade Direção da visão	KHz instalado Zonas de controle Dimerização perfeita Acionamentos complexos Controle lógico Múltiplos sistemas Tipo de luminária e distribuição no espaço
Luminância	Resfriamento	Orientação	Abertura Zenital	Céu	Construções	Funcionamento das persianas	Aquecimento
Relação de contraste Uniformidade Luminosidade/Ofuscamento Gradientes Imagem 3D Qualidade de visualização	Carga adicional kWh anual kW máximo Perfis de carga	Cardial Precisão Latitude Longitude	Tamanho e localização TVIS Esquadria e efeitos do poço de luz Geometria do envidraçamento Fotometria TVIS variáveis BSDF dinâmico	Distribuição uniforme Intensidade horária Distribuição Perez Parcialmente encoberto Nebliina/nevoeiro Precipitação	Declive do horizonte Caixas opacas Refletância difusa Refletância especular Formas complexas Transparência	Acionamento solar Tempo de resposta Acionamento por luminosidade (ofuscamento) Inclinação das aletas (ângulo) Desligamento automático Privacidade, segurança Manutenção	Carga anual Resposta dinâmica Eficiência do sistema
Térmico	Aquecimento	Propriedades Visuais	Persianas internas e cortinas	Térmico	Vegetação	Escolhas para iluminação	Resfriamento
Radiante	Carga adicional kWh anual kW máximo Perfis de carga	Refletância difusa Refletância especular Transparência interna	TVIS Direta x Difusa Programa operacional Múltiplos programas Múltiplos acionadores Ângulo, forma BSDF dinâmico	GDA/GDR Temperaturas horárias Umidade relativa Componente de radiação Velocidade do vento Microclima	Forma e localização Refletância Transparência Variação sazonal Qualidade da visão Automóveis Água	Controle lógico Iluminação de tarefa Desligamento automático Manutenção	Carga anual Resposta dinâmica Eficiência do sistema
Circadiano	Ventilação	Propriedades Térmicas	Persianas externas e toldos		Outros	Cronograma de uso	Ventilação
Sincronização Duração Intensidade Espectro Contexto relativo	Carga adicional kWh anual kW máximo Perfis de carga	Transmitância Fator solar (FS) Capacitância Interações das persianas	TVIS Direta x Difusa Ângulo, forma Cronograma de operação		Qualidade da visão Automóveis Água	Tipo de uso Informação/ programação horária Requisitos de conforto Operação da janela Estilo de gerenciamento do edifício	Carga anual Resposta dinâmica Janelas variáveis
		Localização dos sensores				Demografia	
		Uma ou duas Plano horizontal Plano vertical Qualquer direção de visualização Sensor fotométrico Imagem 3D				Idade Saúde Sensitividade circadiana Status circadiano	

Fonte: Adaptado de: Heshong (2011).

2.1.2 Simulação computacional

As avaliações com medidas dinâmicas só são possíveis através da simulação computacional. A simulação do desempenho de um edifício pode ser definida como um modelo matemático computacional de aspectos do desempenho da edificação baseado em princípios físicos fundamentais e modelos de engenharia (HENSEN, 2006). No caso da iluminação natural, os modelos devem prever a quantidade de luz disponível em um ambiente. Segundo pesquisa de Reinhart e Fitz (2006), os tipos de saída mais usados pelos simuladores são iluminância, FLD, imagens fotorrealistas e luminâncias geradas sob determinada condição de céu, além de consumo de iluminação artificial, índice de ofuscamento e autonomia da luz natural, nessa ordem. A simulação computacional de medidas estáticas, tais como iluminância, DF e luminância, oferece resultados expressos através de imagens fotorrealistas, mas não permite uma avaliação das soluções de projeto ao longo do ano. Os avanços nas análises numéricas do desempenho de espaços iluminados naturalmente apontam para a substituição das simulações estáticas por simulações dinâmicas, baseadas em dados climáticos (MARDALJEVIC; HESCHONG; LEE, 2009). Apontam também para o refinamento da predição de ofuscamento em modelos comportamentais que procuram reproduzir o comportamento do usuário em relação ao uso dos dispositivos de controles de iluminação natural e artificial, além de novos métodos de avaliação que modelam propriedades térmicas e ópticas de sistemas complexos de elementos que compõem as aberturas como sistemas de redirecionamento de luz (REINHART; WIENOLD, 2011). Diversos métodos vêm sendo propostos para modelar simulações dinâmicas anuais, desde os mais básicos, que usam o conceito do FLD, até os mais avançados, que utilizam os Céus Estatísticos e os Coeficientes de Iluminação Natural,⁴ os quais permitem a integração de simulações térmicas e luminosas (REINHART; HERKEL, 2000).

Existem inúmeros métodos para o cálculo da iluminação natural, um dos mais difundidos é o método do fluxo dividido, que calcula a iluminação em um ponto através da soma das componentes diretas e refletidas da iluminação natural (HOPKINSON; PETHERBRIDGE; LONGMORE, 1966; KOTA; HABERL, 2009). Métodos mais

⁴ Coeficiente de Iluminação Natural é um conceito matemático que descreve quanto determinada porção do céu contribui para a iluminação natural em certo ponto do edifício (TREGUENZA; WATERS, 1983).

consistentes foram desenvolvidos na década de 1980 e baseiam-se no comportamento da radiação luminosa (CLARO, 1998). O método da radiosidade fundamenta-se na troca de energia luminosa entre as superfícies consideradas perfeitamente difusas, com base no Fator de Forma. Este método considera as características geométricas do modelo e independe do observador. Já o método do raio traçado aborda a análise do percurso de uma partícula luminosa, da sua emissão até sua absorção, ou vice-versa. Este método apresenta boa resposta quando se trata de fenômenos especulares das trocas luminosas; contudo, depende do ponto de observação, fazendo com que cada visualização exija nova determinação do percurso dos raios luminosos (CLARO, 1999).

O *Building Energy Software Tools Directory* (2011), um diretório disponível na internet e mantido pelo Departamento de Energia do Governo dos Estados Unidos, apresenta informações sobre 417 programas de simulação para avaliar a eficiência energética, energias renováveis e a sustentabilidade em edifícios. Atualmente, 23 desses avaliam a iluminação natural; entretanto, na pesquisa de 2006 de Reinhart e Fitz (2006), mencionada anteriormente, os entrevistados indicaram o uso de 42 programas de simulação de iluminação, tendo 50% dos votos indicado programas baseados no Radiance, que usa o método do raio traçado.

Nem todos esses programas possibilitam simulações anuais. Reinhart, Mardaljevic e Rogers (2006) listaram ferramentas de simulação de iluminação natural baseadas no Radiance que podem ser usadas para simulações dinâmicas. Os programas listados foram Adeline, Daysim, ESP-r, Lightswitch Wizard e SPOT. Os autores afirmam que o método do raio traçado utilizado pelo Radiance, combinado com a abordagem dos Coeficientes de Iluminação Natural e os modelos de céu de Perez, possibilitam, de forma eficiente, o cálculo de séries temporais de iluminâncias e luminâncias (MARDALJEVIC, 2000; REINHART; ANDERSEN, 2006; REINHART; WALKENHORST, 2001).

Para a avaliação do impacto energético do aproveitamento da luz natural de forma global, o programa de simulação deve permitir a modelagem dos fenômenos luminoso e térmico e computar os ganhos térmicos da radiação luminosa, bem como a diminuição do uso do sistema de iluminação artificial e do calor gerado por esse sistema ao longo do ano ou de períodos de tempo. Nesse sentido, alguns métodos de cálculo de iluminação natural foram incorporados por programas de simulação termoenergéticas, como o DOE-2.1B, o eQuest e o EnergyPlus (KOTA; HABERL, 2009). O DOE-2 utiliza o método do

fluxo dividido; entretanto, o método pode superestimar a quantidade de luz nas porções mais afastadas da abertura (WINKELMANN; SELKOWITZ, 1985). Kota e Haberl (2009) indicam limitações quanto à modelagem de estratégias como prateleiras de luz, sistemas complexos de aberturas e iluminação vinda de espaços adjacentes ou átrios. Por fim, o programa utiliza apenas dois modelos de céu, CIE nublado e claro. O eQuest utiliza o mesmo algoritmo do DOE-2, com algumas evoluções na consideração dos modelos de céu. Já o EnergyPlus utiliza modelo de céu de Perez e apresenta duas possibilidades de modelagem de iluminação natural: a primeira derivada do DOE-2 com o método do fluxo dividido e a outra com a radiosidade. O módulo que utiliza a radiosidade permite a modelagem de Sistemas Complexos de Abertura; entretanto, estudos com validações baseadas em medições apontam a superestimação para geometrias complexas (YOON; JEONG; LEE, 2014; YUN; KIM, 2013). Além disso, ambos os métodos apresentam limitações em modelar superfícies especulares. Assim, a integração entre programas de simulação termoenergética e programas puramente de iluminação, mais consistentes como os programas com base no Radiance (método do raio traçado), vem sendo utilizada (DIDONÉ, 2009; RAMOS; GHISI, 2010; VERSAGE; MELO; LAMBERTS, 2010). O método do raio traçado oferece vantagens na modelagem do desempenho físico dos raios de luz e seus efeitos de acordo com as propriedades espectrais dos materiais para qualquer complexidade geométrica (DIDONÉ, 2009; RAMOS; GHISI, 2010; VERSAGE; MELO; LAMBERTS, 2010). A desvantagem desse método é o tempo de simulação. Gibson (2012) comparou três soluções de ambientes, com e sem proteções solares simuladas para quatro programas/algoritmos. A diferença de tempo de simulação entre os dois métodos do EnergyPlus, fluxo dividido (objeto Daylight:Controls) e radiosidade (objeto DE-Light) para os outros dois programas que têm o Radiance (raio traçado) como base, o Daysim e o SPOT, chegou a quase 10 horas para a solução com persianas horizontais, como mostra a Tabela 1.

Tabela 1 – Duração da simulação de iluminação natural para ambientes de diferentes complexidades utilizando diferentes programas (algoritmos)

Programa de simulação de iluminação natural	Tempo de simulação (h:min:s)		
	* ¹ Ambiente sem <i>brise</i>	* ² Ambiente com prateleira de luz interna	* ³ Ambiente com proteção solar horizontal externa
EnergyPlus – Daylight:Controls	0:01:21	0:01:28	6:00:00
EnergyPlus – DE-Light	0:02:06	0:02:26	6:49:00
Daysim	4:04:00	3:05:00	11:00:00
SPOT	5:00:00	5:34:00	15:33:00

Fonte: Adaptado de: Gibson (2012, p. 90).

Notas:

*¹ :Simulações realizadas em um computador com processador dual core 2.26 GHz 4GB RAM.

*² Simulações realizadas em um computador com processador dual core 2.09 GHz 1GB RAM.

*³:Simulações anuais executadas.

Todos esses programas apresentam códigos complexos, porém abrangentes, assim como interfaces mais detalhadas, exigindo numerosos dados de entrada para a caracterização de modelos virtuais (CRAWLEY et al., 2005; MENDES et al., 2005). As ferramentas de simulação podem ser usadas para fins múltiplos em diferentes etapas do projeto ou da edificação pronta. Haghghat e Marsh (2004) enfatizam a necessidade de a simulação computacional ser mais difundida nas fases iniciais de projeto, quebrando antigos paradigmas de ser utilizada apenas como validação de soluções já definidas (por exemplo, atendimento a códigos e normas). Nesse sentido, Westphal (2007) desenvolveu um método para auxiliar na calibração de modelos para simulações computacionais do desempenho termoenergético de edificações. A calibração objetiva reduzir as incertezas do modelo e a quantidade de simulações ao permitir que os projetistas identifiquem as variáveis mais influentes no modelo. Outra questão é tornar os resultados das simulações mais acessíveis aos envolvidos no processo de projeto. Para auxiliar o projetista na tomada de decisões, Reinhart e Wienold (2011) propuseram um “painel de controle” que traz gráficos com informações sobre disponibilidade de iluminação natural, conforto dos ocupantes e energia.

Na ausência de informações detalhadas da edificação, inerentes às fases iniciais de projeto, uma alternativa é o uso de ferramentas de simulação simplificadas. Outra alternativa é o uso de ferramentas

baseadas em simulações pré-realizadas. Pedrini e Szokolay (2005), por exemplo, propuseram uma ferramenta para estimar o impacto das decisões arquitetônicas sobre o consumo da energia elétrica durante as fases iniciais de projeto, utilizando um banco de dados. Venâncio e Pedrini (2009) observaram uma economia de 27,4% atribuída a decisões na etapa conceitual.

As simulações pré-realizadas ainda podem ser utilizadas para a proposição de metamodelos de abordagem estatística como técnicas de regressões realizadas com base em casos simulados (KILMER, 1994; MELO, 2012). Uma das principais vantagens de ferramentas é a redução do tempo de simulação, visto que a simulação de iluminação natural isoladamente ou integrada à simulação térmica, além de exigir elevado conhecimento técnico, pode demorar de minutos a horas, dependendo da complexidade do modelo (REINHART, 2001).

2.2 MÉTODOS SIMPLIFICADOS PARA AVALIAÇÃO DE ILUMINAÇÃO NATURAL NO AMBIENTE INTERNO

Métodos simplificados são ferramentas idealizadas para dar respostas rápidas sem necessitar de significativo detalhamento de informações. Normalmente, são utilizados para comparar o desempenho de diferentes soluções de projeto, especialmente, na etapa conceitual. Porém, não são indicados para modelar estratégias complexas envolvendo iluminação natural ou mesmo para refinar estratégias projetuais (IEA, 2000). Além de auxiliarem na tomada de decisões, também podem ser usados para avaliar a conformidade de projetos de acordo com índices mínimos estabelecidos por instrumentos regulatórios.

Este tópico da revisão bibliográfica foi desenvolvido a partir de uma pesquisa sobre ferramentas simplificadas como parte da TASK 21 da IEA (2000). Procurou-se adicionar novas ferramentas divulgadas na bibliografia de acordo com a classificação apresentada pela pesquisa e avaliadas segundo critérios de interesse deste trabalho. O principal objetivo foi definir uma lacuna com a qual este trabalho pudesse contribuir cientificamente. As 72 ferramentas encontradas foram analisadas quanto a sua proposição de avaliar: A – Representação do fenômeno da luz e, quando aplicável, do fenômeno térmico, B – Parâmetros do edifício; C – Contexto do edifício; D1 – Desempenho do edifício e D2 – Implementação.

A partir dessa classificação, elencou-se a principal limitação dos métodos segundo a ótica deste trabalho, de forma a oferecer um

panorama do estado da arte de ferramentas simplificadas que tem como foco a iluminação natural. Esse processo, bem como o seu produto, os quadros de análise, são apresentados no APÊNDICE A .

A pesquisa de referência fez parte da *Subtask C: Daylighting Design Tools* da TASK 21 e classificou os métodos simplificados em oito categorias: I. Fórmulas empíricas, II. Tabelas, III. Nomogramas, IV. Diagramas, V. Transferidores, VI. Aplicativos computacionais, VII. Tipologias e VIII. Modelos em escala (DE BOER; ERHORN, 1999). Com base na classificação proposta, incluiu-se uma nova categoria: IX. Ferramentas estatísticas/computacionais.

As ferramentas simplificadas podem ser separadas em dois grupos principais: o primeiro abarca as ferramentas anteriores a tecnologias computacionais acessíveis (I. Fórmulas empíricas, II. Tabelas, III. Nomogramas, IV. Diagramas, V. Transferidores e VIII. Modelos em escala); e o segundo abrange as ferramentas historicamente mais recentes que são normalmente baseadas na tecnologia computacional (VI. Aplicativos computacionais, VII. Tipologias e IX. Ferramentas estatísticas/computacionais).

Na categoria I. Fórmulas empíricas estão as “Regras Práticas” (*Rules of Thumbs*), ainda largamente utilizadas entre os arquitetos (PEREIRA et al., 2005). Essas são geralmente destinadas aos usuários que dispõem de dados de entrada mínimos. Os resultados fornecem diferentes graus de informações de projeto.

Na outra ponta estão os VII. Aplicativos computacionais, que, em geral, se dividem em dois grupos: no primeiro, as interfaces gráficas que recorrem a resultados pré-simulados ou que avaliam automaticamente conjuntos de equações e/ou combinações dessas duas alternativas; o segundo trata de ferramentas de interface amigável que criam arquivos de entrada para simulações mais complexas de iluminação natural/energéticas que não necessitam de um especialista para serem operadas. Como se trata de simulações computacionais, tendem a demandar mais tempo para a obtenção de resultados que as primeiras. Entretanto, em geral, permitem uma maior liberdade na definição de parâmetros de entrada. Não são contemplados nessa definição programas de simulação complexos, que permitem ainda maior liberdade de modelagem, mas exigem maior tempo de simulação, maior definição das características do edifício e muitas vezes a manipulação por parte de um especialista.

As IX. Ferramentas estatísticas/computacionais, bastante difundidas na atualidade, possibilitam uma resposta rápida, já que, normalmente, se baseiam em dados medidos ou pré-simulados através

de simulação computacional detalhada. Grande parte dos casos utiliza regressões multivariadas lineares ou não lineares. As últimas possibilitam uma maior aproximação para representar relações não lineares entre as variáveis. Nesses casos, são comumente abordadas como metamodelos, isso porque se trata de modelos estatísticos/computacionais baseados em outros modelos (os modelos matemáticos adotados pelo programa de simulação computacional) (KILMER, 1994; MEISEL; COLLINS, 1973; ROTMANS; VRIEZE, 1990).

Vale ressaltar que algumas ferramentas alocadas em grupos como II. Tabelas e III. Nomogramas, por exemplo, foram desenvolvidas com base em simulação computacional e análises estatísticas, mas geraram como ferramenta para o uso do projetista tabelas ou nomogramas, por isso foram alocadas nestes grupos.

De acordo com o que foi observado nesse levantamento, as ferramentas que objetivam definir tamanhos mínimos de aberturas e um zoneamento de iluminação natural, em geral, não consideram a influência da refletância das superfícies, a diferença das orientações ou as condições dinâmicas do céu.

Já as ferramentas que objetivam prever o impacto da luz natural no desempenho energético, em sua maioria, baseiam-se no fator de luz diurna. Por se tratar de um fator que representa as condições de iluminação sob um céu encoberto e desobstruído, desconsidera as condições dinâmicas do céu com sol e com diferentes condições de nebulosidade e, conseqüentemente, a orientação. Com o mesmo objetivo, os métodos simplificados apresentados em normas como a TITLE 24 (CALIFORNIA ENERGY COMMISSION, 2013) e a ASHRAE 90.1 (ASHRAE, 2013) aplicam fatores de redução de potência instalada para ambientes que utilizam fotocontroles, aproveitando a luz natural. Contudo, não diferenciam a localidade ou a influência das refletâncias internas.

Ainda sob o enfoque do desempenho energético, as IX. Ferramentas estatísticas/computacionais utilizadas como metamodelos apresentam a vantagem de modelar mais facilmente o impacto do aproveitamento da luz natural de forma global. Isso porque os modelos de simulação complexa (luminosa, térmica e de energia) nos quais se baseiam conseguem representar a influência do consumo do sistema de iluminação artificial e de condicionamento de ar. Dentre os casos encontrados na bibliografia, todos apresentaram pelo menos uma das limitações apontadas a seguir. Como base de dados para a regressão, adotam para a simulação do fenômeno da luz natural o programa

EnergyPlus, que, até o momento, apresenta limitações em seu algoritmo (ver item 2.1.2, p. 63). Ainda, por influência das simulações térmicas, dividem o modelo em cinco zonas com aberturas em todas as fachadas. Dessa forma, esses modelos perdem a sensibilidade ao parâmetro orientação, fundamental para a iluminação natural, que é mais bem observada no nível do ambiente. A distribuição de aberturas em todas as faces também não caracteriza a realidade da maioria dos edifícios. Por fim, a mesma porcentagem de abertura distribuída em diferentes orientações apresenta desempenhos diferentes; logo, a generalização, nesse caso, não se mostra adequada.

Dois dos trabalhos levantados mereceram maior discussão devido à afinidade com esta tese: o trabalho de Didoné e Pereira (2010), por utilizar regressão linear multivariada baseada em simulação integrada (Daysim/Radiance e EnergyPlus); e o trabalho de Wong, Wan e Lam (2010), por utilizar redes neurais artificiais para a metamodelagem.

O trabalho de Didoné e Pereira (2010), que utilizou a simulação integrada e considerou apenas uma zona térmica por ambiente, se baseou em regressão linear multivariada, limitada para modelar relações não lineares. O zoneamento utilizado pelos autores estipulou uma zona termoluminosa que coincidia com a área total do ambiente. O parâmetro orientação foi excluído do modelo por não ter sido considerado representativo na análise estatística. Entretanto, entende-se que esse parâmetro pode ser estudado com mais profundidade devido a sua importância para o fenômeno da iluminação natural. Além disso, neste trabalho, as propriedades dos vidros foram expressas somente pelo parâmetro Fator Solar, desconsiderando-se a Transmissão Visível. Como representação das proteções solares, foram adotados ângulos de sombreamento.

A proposta de Wong, Wan e Lam (2010) será mais bem discutida no item 2.3.7.3, p. 97, deste capítulo, depois da apresentação do referencial teórico sobre redes neurais artificiais. Os autores utilizaram RNAs para metamodelagem energética considerando a iluminação natural e obtiveram forte correlação (coeficiente Nash–Sutcliffe de 0,994), indicando elevado potencial de predição do consumo energético. Entretanto, este trabalho baseia-se em simulações do EnergyPlus, cujas limitações para a modelagem da iluminação natural já foram apontadas. Os autores utilizaram a abordagem térmica para a definição das zonas, assim a influência das orientações foi mitigada devido ao agrupamento das zonas térmicas para a avaliação do balanço final.

A pesquisa por métodos simplificados levantou que, embora exista uma grande quantidade de ferramentas que contemplam a

iluminação natural, existe um número reduzido delas que oferece a possibilidade de avaliação do impacto no consumo energético, considerando as implicações no padrão de uso do sistema de iluminação artificial, e no condicionamento de ar. Além disso, as que existem apresentam limitações inerentes à sua concepção (algoritmos e métodos: por exemplo, *split flux*) ou aplicação (definições no processo metodológico: por exemplo, agrupamento de zonas térmicas).

O levantamento das ferramentas por categorias permitiu observar as oportunidades de contribuição deste trabalho. Assumiu-se que o desenvolvimento de uma ferramenta simplificada que contemple a predição do consumo energético considerando a iluminação natural deve levar em conta o dinamismo das condições de céu e as características arquitetônicas que influenciam o desempenho da luz natural, o impacto no sistema de iluminação e no de condicionamento de ar. Nesse sentido, as IX. Ferramentas estatísticas/computacionais apresentaram um forte potencial de atender a essa demanda. As redes neurais artificiais, por tratarem de regressão não linear, são indicadas para aproximar funções que envolvam variáveis que não apresentem relação linear, como acontece com as variáveis do edifício. Além disso, possuem elevado poder de generalização, o que permite que estendam o que adquiriram por aprendizado às soluções que não lhes foram apresentadas.

Assim, torna-se importante um aprofundamento no estudo dessa ferramenta, de modo a verificar a sua aplicabilidade para modelar o fenômeno da iluminação, considerando os efeitos importantes como o da orientação, de climas de diferentes localizações, de variáveis arquitetônicas, entre outros.

No caso do desenvolvimento de um método simplificado que possa ser utilizado tanto para avaliações nas fases iniciais de projeto quanto para avaliações de desempenho, é interessante combinar o método de avaliação de desempenho de diferentes configurações de ambiente com o zoneamento de luz natural. O zoneamento permite definir quais áreas podem ser beneficiadas pelo aproveitamento da luz natural. No caso da utilização de zoneamento, os métodos levantados deixam uma lacuna quanto ao impacto do dinamismo das condições de céu e da orientação para o zoneamento da iluminação natural.

Baseando-se nessas considerações, o próximo item discute a teoria das redes neurais artificiais e as aplicações desse método estatístico.

2.3 FUNDAMENTAÇÃO TEÓRICA: REDES NEURAIIS ARTIFICIAIS

As redes neurais artificiais (RNAs) são técnicas computacionais que utilizam modelo matemático inspirado na estrutura biológica do cérebro humano, fazendo uma analogia com o funcionamento do neurônio e suas conexões. Essas técnicas buscam reproduzir o comportamento e a dinâmica do cérebro, adquirindo conhecimento através da experiência (SILVA et al., 2004). As RNAs têm por objetivo fornecer subsídios para que a ferramenta computacional consiga, baseada em um conjunto de simulações conhecidas, estender tais informações para determinada situação proposta (COSTA, 2001).

Haykin (2001) define como benefícios das redes neurais (i) sua estrutura maciça e paralelamente distribuída; e (ii) sua habilidade de aprender e conseqüentemente de generalizar. Isso quer dizer que a RNA é capaz de reproduzir resultados (dados de saída) adequados para dados de entrada que não pertenceram ao treinamento (processo de aprendizagem).

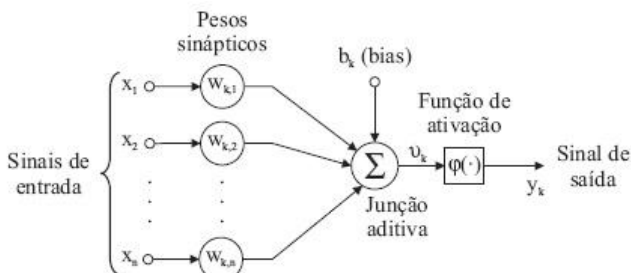
A utilização de RNAs tem sido crescentemente observada no contexto de aproximação de funções. Visando verificar suas aplicações diante do tema deste trabalho, a revisão de literatura foi estruturada sob dois aspectos: aplicações referentes ao comportamento energético de edificações e ao fenômeno da iluminação natural. Os trabalhos acessados tiveram sua abordagem dividida em seis categorias: I. Modelagem do desempenho termoenergético em edificações, II. Previsão de demanda futura de energia, III. Aplicações em sistemas de controles visando à eficiência energética, IV. Suporte para tomadas de decisão, calibração e/ou otimização de projetos e sistemas do edifício, V. Previsão de iluminâncias e VI. Modelagem do desempenho energético global (térmico + luminoso).

Assim, este item foi dividido em duas etapas principais: na primeira será apresentado o embasamento teórico e conceitual das RNAs sob o enfoque adotado para esta tese; e na segunda será exibido o estado da arte do uso de RNAs aplicadas para a modelagem do comportamento energético em edifícios segundo as seis categorias mencionadas. Por fim, discutem-se as possibilidades de aprofundamento de estudos considerando a aplicação de RNAs para modelagem do desempenho global, destacando-se o aproveitamento da iluminação natural.

2.3.1 O neurônio artificial

A estrutura básica de uma RNA é o neurônio. Haykin (2001) define o neurônio artificial como uma unidade de processamento matematicamente simples, pois recebe uma ou mais entradas, que, por sua vez, têm um peso associado, e as transforma em saídas. Pode-se complementar ainda que o neurônio é composto de uma função soma,⁵ responsável pelo cálculo da entrada efetiva para o neurônio, e uma função ativação,⁶ que transmite o sinal de saída (ver Figura 4). Analogamente ao neurônio biológico, as entradas são os dendritos; a função soma é o corpo celular no qual ocorrem as sinapses (ajuste dos pesos); e a função de transferência é o axônio, que dispara um sinal quando excitada.

Figura 4 – Modelo não linear de um neurônio artificial



Fonte: Haykin (2001).

Observando a Figura 4, pode-se prestar atenção em alguns elementos importantes para a descrição do neurônio artificial: os sinais de entrada, os pesos sinápticos, a junção aditiva ou função soma, os desvios (*bias*), a função de ativação e os sinais de saída.

Os sinais de entrada, também chamados de padrões de entrada, parâmetros de entrada ou estímulos, no caso deste estudo, serão as características do edifício ou do contexto no qual ele está inserido (por exemplo, valores de PAF, T_{VIS} , latitude etc.). Os pesos sinápticos são

⁵ Função soma: soma os sinais de entrada, ponderados pelas respectivas sinapses (pesos) do neurônio.

⁶ Função de ativação: restringe a amplitude de saída de um neurônio. Limita o intervalo permissível de amplitude do sinal de saída a um valor finito, normalizado como o intervalo unitário fechado (0,1) ou (-1,1). É a função responsável pela propagação da saída de um neurônio para os demais neurônios.

definidos randomicamente pelo programa computacional e vão sendo ajustados conforme algoritmos de aprendizagem,⁷ que serão abordados no item 2.3.6. A saída, os padrões de saída, os parâmetros de saída ou a resposta são as variáveis que se pretende obter (por exemplo, consumo energético, iluminâncias etc.).

O conhecimento da rede é representado pelos pesos sinápticos, que determinam a importância que cada entrada possui. A influência que cada entrada terá na saída será tanto maior quanto mais estimulada for uma conexão sináptica,⁸ ajustada de acordo com os processos de aprendizagem, que serão apresentados no item 2.3.4. Resumidamente, o neurônio processa os valores de entrada através da realização da soma desses valores ponderados pelos pesos sinápticos respectivos. A função ativação é, então, aplicada a essa soma ponderada com o intuito de manter o sinal de saída dentro de um limite finito e de introduzir a não linearidade ao modelo.

As sinapses são caracterizadas por um peso (w), inicialmente aleatório, que representa sua intensidade. O peso w_{kj} multiplica o sinal x_j , na entrada da sinapse j , conectada ao neurônio k . O resultado dessa operação é submetido a um Limiar (θ), ou *threshold*, que é associado à função de ativação ou transferência. O limiar é fundamental, pois é ele que define se o sinal será propagado ou não. Se o valor v_k for maior que esse limiar, o peso w_{kj} será positivo e o neurônio ficará ativo (ação excitatória); caso contrário, se for menor que o limiar, o sinal será negativo e a saída do neurônio ficará inibida (ação inibitória).

A função soma é um somatório que adiciona as entradas ponderadas pelos seus respectivos pesos, dada pela Equação 1:

⁷ Algoritmo de aprendizagem: pode ser definido como um conjunto preestabelecido de regras bem definidas para a solução de um problema de aprendizagem (HAYKIN, 2001).

⁸ Conexão sináptica: as sinapses são unidades estruturais e funcionais elementares que intermediam as interações entre os neurônios. Na organização neural, uma sinapse é uma conexão simples que pode impor ao neurônio receptivo excitação ou inibição, mas não ambas (HAYKIN, 2001).

$$u_k = \sum_{i=1}^n w_{ij} * x_j \quad (1)$$

Onde:

u_k : saída do combinador linear devido aos sinais de entrada para o neurônio k ;


w_{ij} : peso sináptico que conecta a saída do neurônio i à entrada j no neurônio;

x_j : sinal de entrada (padrão de entrada); e

n : o n -ésimo padrão de treinamento (exemplo) apresentado à rede.

A função de ativação (φ) tem a função de restringir a amplitude da saída do neurônio. Normalmente, a entrada é normalizada dentro de um intervalo unitário fechado (0,1) ou como alternativa (-1,1). Haykin (2001) identifica três tipos básicos de função de ativação (ver Figura 5): limiar (ver Equação 2), linear por partes (ver Equação 3) e sigmoide (ver Equação 4).

Figura 5 – Funções de ativação



(a) Função limiar

(b) Função linear por partes

(c) Função sigmoide

Fonte: adaptado de: Bocanegra (2002).

Para a função limiar, tem-se que:

$$\varphi(v) = f(x) = \begin{cases} 1 & se \geq 0 \\ 0 & se < 0 \end{cases} \quad (2)$$

Onde:

φ : função ativação; e

v : campo local induzido ou potencial de ativação.

A função linear por partes fica como segue.

$$\varphi(v) = \begin{cases} 1, & v \geq +1/2 \\ v, +\frac{1}{2} > v > -1/2 \\ 0, & v \leq -1/2 \end{cases} \quad (3)$$

Onde:

φ : função ativação; e

v : campo local induzido ou potencial de ativação.

A função sigmoide é a função de ativação mais comum utilizada na construção de RNAs; é definida por uma equação estritamente crescente que exhibe um adequado balanceamento entre comportamento linear e não linear e dada pela Equação 4:

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (4)$$

Onde:

φ : função ativação;

a : é o parâmetro da inclinação da sigmoide; e

v : campo local induzido ou potencial de ativação.

Um *bias* ou desvio (b_k) tem o efeito de aumentar ou reduzir a entrada líquida da função ativação, dependendo se é positivo ou negativo, respectivamente. O *bias* permite aumentar o grau de liberdade, garantindo uma melhor adaptação da RNA à função.

Por fim, a saída do neurônio, y_k , é dada pela Equação 5:

$$y_k = \varphi(u_k + b_k) \quad (5)$$

Onde:

y_k : sinal de saída do neurônio;

φ : função ativação;

u_k : saída do combinador linear devido aos sinais de entrada para o neurônio k ; e

b_k : bias ou desvio.

2.3.2 A arquitetura da rede


A forma como os neurônios estão estruturados na rede neural está fortemente relacionada com o algoritmo de aprendizagem utilizado para treinar a rede (HAYKIN, 2001). Os algoritmos de aprendizagem determinam as regras que serão utilizadas para o aprendizado. Os algoritmos abordados neste trabalho serão explicados no item 2.3.6.

Existem várias tipologias de RNAs; contudo, elas podem ser agrupadas em duas classes básicas: (i) Não recorrentes e (ii) Recorrentes (BOCANEGRA, 2002).

As RNAs não recorrentes são ditas “sem memória” por não possuírem realimentação de suas saídas para suas entradas. Essas RNAs são estruturadas em camadas e podem ser formadas por uma ou mais camadas, denominadas RNA de camada única e RNA multicamadas, respectivamente.

Na rede de camada única tem-se uma camada de entrada de nós de fonte, também chamada *perceptron*,⁹ que se projeta sobre uma camada de saída de neurônios, mas não vice-versa, podendo ser classificada como do tipo acíclica (ver Figura 6).

Figura 6 – Exemplo de rede alimentada adiante ou acíclica (*feedforward*) com uma única camada de neurônios




Fonte: Adaptado de: Haykin (2001).

⁹ *Perceptron* ou perceptron de Rosenblat é a forma mais simples de uma RNA usada para padrões linearmente separáveis. Basicamente, ele consiste em um único neurônio com pesos sinápticos ajustáveis e desvios (*bias*). É um classificador binário que mapeia sua entrada (x), um vetor de valor real, para um valor de saída $f(x)$ e um valor binário simples, através de uma matriz (HAYKIN, 2001).

As redes alimentadas adiante com múltiplas camadas distinguem-se da anterior pela presença de camadas ocultas (uma ou mais), cujos nós computacionais são conhecidos como neurônios ou unidades ocultas. Sua função é intervir de maneira útil entre a entrada e a saída da rede, tornando-a capaz de extrair estatísticas de ordem elevada¹⁰ (ver Figura 7) (HAYKIN, 2001).

Figura 7 – Exemplo de rede alimentada adiante ou acíclica (*feedforward*) totalmente conectada com uma camada oculta e uma camada de saída

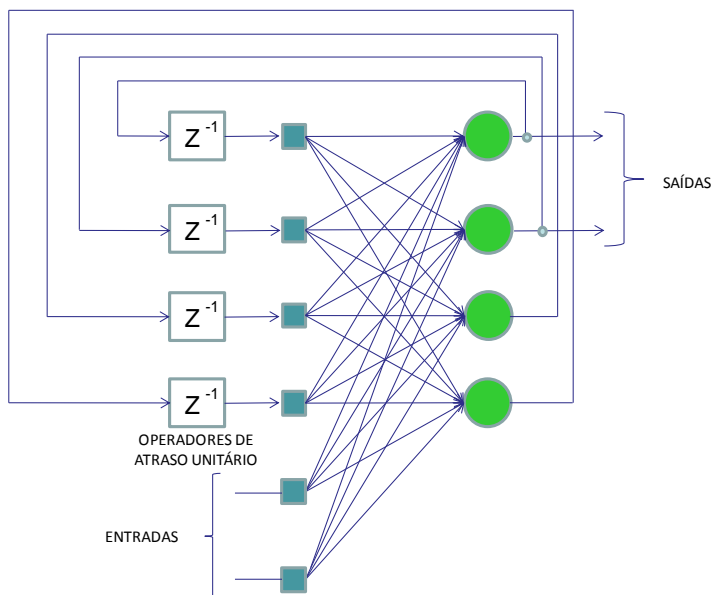


Fonte: Adaptado de: Haykin (2001).

As redes recorrentes possuem realimentação das saídas para as entradas, sendo suas saídas determinadas pelas entradas atuais e pelas saídas anteriores. Suas estruturas não se organizam necessariamente em camadas e, quando o são, podem possuir ligações entre neurônios de camadas não consecutivas ou ligações entre neurônios de mesma camada. Com isso, geram interconexões superiormente mais complexas que as RNAs não recorrentes, conforme mostra a Figura 8 (BOCANEGRA, 2002).

¹⁰ Estatística de ordem elevada ou superior: fundamenta-se em medidas estatísticas de ordem superior, normalmente acima da terceira ordem (implícita ou explícita), apresentam maior imunidade a ruídos gaussianos (FERREIRA et al., 2009; SILVA, 2009).

Figura 8 – Exemplo de rede recorrente com neurônios ocultos



Fonte: Adaptado de: Haykin (2001).

2.3.3 Redes *perceptron* multicamadas

Estes tipos de redes constituem os modelos RNA mais difundidos no momento devido a sua maior capacidade de aprendizagem. Consistem em um conjunto de unidades sensoriais que forma uma camada de entrada, uma ou mais camadas intermediárias de unidades ocultas e uma camada de saída. A propagação dos sinais de entrada acontece de camada a camada na direção positiva (da entrada para a saída) (BOCANEGRA, 2002).

Cada unidade da camada intermediária funciona como um *perceptron*; entretanto, sua função é a limiar ou a sigmoide. O tipo de ativação escolhido se dá de forma a suavizar a atualização dos pesos, evitando alterações bruscas (COSTA, 2001).

As redes *perceptron* multicamadas – PMC (*multilayer perceptron* – MLP) têm sido aplicadas de maneira satisfatória para problemas envolvendo alto grau de não linearidade. O processo de aprendizagem aplicado às PMCs é do tipo supervisionado, explicado no item a seguir. O algoritmo utilizado é o chamado retropropagação do erro (*error backpropagation*), que se baseia numa regra de aprendizagem que busca

corrigir o erro durante a fase de treinamento, visto com mais detalhes no item 2.3.6 (HAYKIN, 2001).

2.3.4 Processos de aprendizagem

A habilidade de aprender é uma das principais propriedades de uma rede neural. Haykin (2001) define aprendizagem como

[...] um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre. (HAYKIN, 2001, p. 75).

A modificação dos parâmetros referida por Haykin (2001) traduz-se no ajuste dos pesos sinápticos, visto que uma rede com pesos sinápticos adequados pode representar praticamente qualquer função. Logo, a aprendizagem consiste no processo de encontrar os pesos adequados. Para tal, inicia-se o processo adotando-se pesos arbitrários e, interativamente, como já explanado, aplicando um algoritmo de aprendizagem (ver item 2.3.6, p. 83); assim, a rede pode chegar ao desempenho desejado.

Em outras palavras, o treinamento de uma rede neural tem por objetivo produzir um conjunto de saídas desejadas ou mesmo consistentes através da aplicação de determinado conjunto de entradas. Cada um desses conjuntos (de entrada ou saída) denomina-se vetor. Realiza-se o treinamento através da aplicação sequencial de vetores de entrada e, algumas vezes, também os de saída, enquanto se ajustam os pesos da rede conforme um procedimento de treinamento escolhido previamente. Durante o processo de treinamento, os pesos vão gradualmente convergindo para determinados valores, até que os vetores de entrada produzam as saídas desejadas (BOCANEGRA, 2002).

Para melhorar o aprendizado da rede, a escolha do conjunto de treinamento deve considerar valores extremos, visto que as RNAs apresentam elevado poder de interpolação, mas limitações quanto à extrapolação.

Os procedimentos de treinamento podem ser classificados de duas formas principais: (i) aprendizagem com um professor e (ii) aprendizagem sem um professor.

A primeira, também chamada de aprendizagem supervisionada, utiliza o conceito do “professor” como tendo o conhecimento sobre o

ambiente, sendo esse conhecimento representado por um conjunto de exemplos de entradas-saídas.

O processo de treinamento funciona da seguinte maneira: aplica-se o vetor de entrada, a saída da rede é calculada e comparada com o vetor-alvo correspondente. Encontra-se um erro que é realimentado através da RNA, sendo os pesos atualizados de acordo com o algoritmo escolhido com o objetivo de minimizar esse erro (os algoritmos são detalhados no item 2.3.6, p. 83). Repete-se o processo até que o erro para os vetores de treinamento alcance níveis aceitáveis (BOCANEGRA, 2002). Essa forma de aprendizagem descrita é a forma de aprendizagem por correção do erro; é nessa regra de aprendizagem que se baseia o algoritmo da retropropagação do erro utilizado neste trabalho e, portanto, explanado no item 2.3.6, p. 83.

Haykin (2001) subdivide o processo de aprendizagem sem professor em duas categorias: aprendizagem por esforço e aprendizagem não supervisionada. Neste tipo de aprendizagem, não há exemplos rotulados da função a ser aprendida pela rede. Segundo Pizarro (2005), este tipo de aprendizagem necessita de um grande número de dados de entrada. Isso porque a rede aprende por si só, não havendo uma mensagem externa de erro. Além disso, as entradas devem ser parecidas para que se possam extrair características estatisticamente relevantes e criar parâmetros automaticamente.

2.3.5 Definição das camadas intermediárias

A definição do número de camadas e da quantidade de neurônios ocultos nessas camadas de uma rede RNA-PMC é feita de maneira empírica e depende da complexidade do próprio problema. É atribuído à camada intermediária o poder de aprendizagem da rede neural. O ajuste do número de neurônios tem dois objetivos principais: garantir as capacidades de convergência e generalização da rede e maximizá-las.

A convergência remete ao desempenho da fase de treinamento e avalia a capacidade de aprendizado da rede. Erros baixos para o conjunto de treinamento significam boa convergência dos resultados. Já a generalização refere-se ao desempenho da fase de testes. Expressa a capacidade da rede de estender o que aprendeu para padrões nunca vistos. Uma rede subdimensionada para o problema que deverá modelar terá dificuldades em aprender e convergir os resultados dos padrões de saída para os dados apresentados na etapa de treinamento, podendo, inclusive, tornar este último muito demorado devido à dificuldade em buscar uma representação ótima (BRAGA; LUDEMIR; CARVALHO,

2000). Já uma rede hiperdimensionada penalizará o poder de predição do conjunto de teste, podendo levar a rede ao treinamento excessivo ou superajuste, já que, além de decorar os padrões, a rede pode acabar aprendendo os ruídos do conjunto de dados (SILVA, 2005). O treinamento excessivo pode ser causado pelo ajustamento demasiado do modelo ao conjunto de treinamento, normalmente devido ao excesso de neurônios na camada intermediária. Ocorre depois de certo tempo de treinamento, quando a RNA memoriza padrões que já foram apresentados e o processo piora sensivelmente.

A quantidade ótima de neurônios geralmente é obtida através de uma série de experimentações. Entretanto, existem alguns teoremas que se propõem a aproximar o número de neurônios na camada oculta; entretanto, não há comprovação de que resultem na melhor configuração de rede. Três deles, que foram adotados ao longo deste trabalho, são descritos a seguir.

Hecht-Nielsen (1987), baseados no teorema de Kolmogorov, demonstraram que a primeira camada oculta de uma rede neural pode ser dada pela Equação 6. Através dessa aproximação, os autores afirmaram que qualquer função de n variáveis poderia ser representada pela referida equação.

$$N_{OCULTOS} = (2 * N_V + 1) \quad (6)$$

Onde:

$N_{ocultos}$: número de neurônios na camada oculta (vetores); e

N_V : número de variáveis de entrada.

Upadhyaya-Eryurek (1992) propuseram a Equação 7, baseados na teoria de Shannon e Waerve's e partindo dos pressupostos de que redes de três camadas são suficientes para resolver problemas de estimação e de que o número mínimo de neurônios ocultos é $\log_2 P$, em que P é o número de padrões do conjunto de treinamento.

$$N_{OCULTOS} = N_V * \log_2 P \quad (7)$$

Onde:

$N_{ocultos}$: número de neurônios na camada oculta;

N_V : número de variáveis de entrada (vetores); e

P: número de padrões de entrada.

Uma terceira heurística comumente encontrada em fóruns de discussão sobre redes neurais é apresentada na Equação 8.

$$N_{OCULTOS} = 1,5 * N_V \quad (8)$$

Onde:

$N_{ocultos}$: número de neurônios na camada oculta (vetores); e

N_V : número de variáveis de entrada.

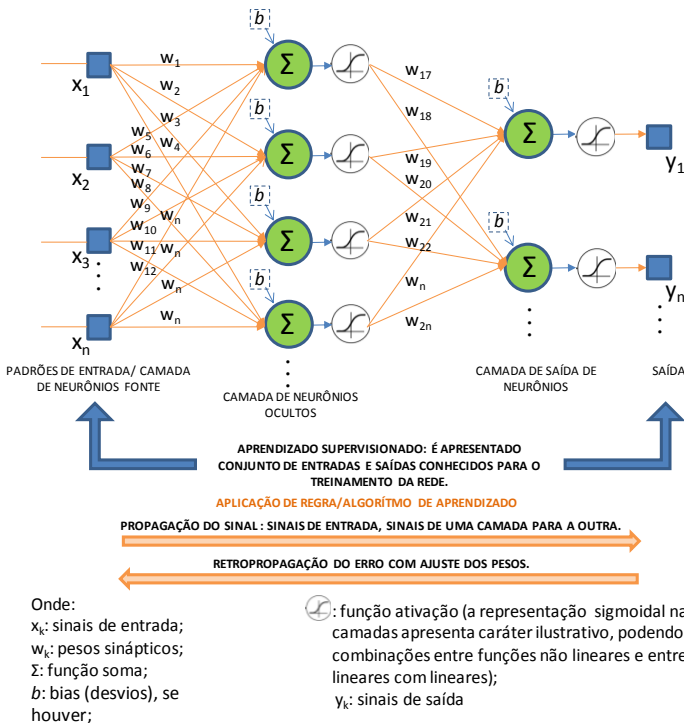
Cabe salientar que cada neurônio acrescido na arquitetura da rede aumenta o seu tempo de processamento de forma exponencial.

2.3.6 Algoritmo da retropropagação do erro (*backpropagation*)

O algoritmo da retropropagação consiste em dois passos através de diferentes camadas da RNA: a propagação (passo para frente) e a retropropagação (passo para trás). Haykin (2001) descreve que, na propagação, um padrão de atividade (vetor de entrada) é aplicado aos nós sensoriais da rede e seu efeito se propaga através da rede camada por camada, produzindo um conjunto de saídas como resposta real da rede. Nesse passo, os pesos sinápticos da RNA são todos fixos. Já durante a retropropagação, ocorre o ajuste dos pesos de acordo com a regra da correção do erro, calculando-se o erro quadrático médio (EQM) das saídas (ver Figura 9). Em outras palavras, a resposta real da rede é subtraída da resposta-alvo, produzindo um sinal de erro. Esse, por sua vez, é propagado através da RNA na direção inversa das conexões sinápticas (daí a nomenclatura retropropagação do erro). Para que a

resposta real se aproxime da resposta-alvo em um sentido estatístico, os pesos sinápticos são ajustados.

Figura 9 – Detalhe do funcionamento de uma rede PMC com algoritmo da retropropagação do erro



Fonte: Autor.

A seguir são apresentadas as três regras para aplicação desse algoritmo abordadas neste trabalho. Ao longo do trabalho são chamados de algoritmos, seguidos do nome da regra.

2.3.6.1 *Gradiente Descendente*

A regra da correção do erro, mencionada anteriormente e adotada originalmente pelo algoritmo da retropropagação, é a do Gradiente Descendente ou da regra delta. Nessa regra, quando um padrão é apresentado à rede, essa irá produzir uma saída. A distância entre o resultado esperado e o resultado medido e a direção do erro são, então,

verificadas utilizando o erro quadrático médio (EQM). Com base nesse resultado, os pesos sinápticos são ajustados de forma a reduzir essa distância, ou seja, aproximar o resultado produzido pela rede do resultado esperado. Seguindo esse processo, o erro tende a ser reduzido com a atualização dos pesos. Entretanto, deve-se atentar para que não se caia em um mínimo local da superfície do erro; para sair de um mínimo local,¹¹ na atualização dos pesos, utiliza-se um termo proporcional à última direção de alteração de peso chamado de momento.

Essa regra, aplicada através do algoritmo do Gradiente Descendente, apresenta críticas quanto ao tempo de treinamento. Visando reduzir esse tempo, uma série de propostas foram desenvolvidas, algumas utilizando heurística, como taxa de aprendizagem adaptativa e retropropagação do erro resiliente (*resilient backpropagation*), e outras utilizando métodos de otimização numérica, como os métodos de Newton e de Levenberg-Marquardt. Além disso, existem algumas técnicas que podem melhorar a generalização da rede e evitar o superajuste (*overfitting*). Entre elas, está o processo de regularização, que permite modificar a função utilizada de forma a diminuir os pesos sinápticos e os desvios (*bias*), forçando a rede a dar respostas mais suaves e evitando o ajuste excessivo dos pesos (THE MATHWORKS INC., 2014).

2.3.6.2 *Levenberg-Marquardt*

O algoritmo Levenberg-Marquardt também é uma regra da correção do erro desenvolvida para a otimização e a aceleração de convergência do algoritmo da retropropagação do erro (SILVA; ALMEIDA; YAMAKAMI, 2012). Também é baseado nos mínimos quadrados, mas propõe uma solução híbrida com propriedades do algoritmo do Gradiente Descendente e o método iterativo Gauss-Newton. O primeiro é utilizado na consideração da inclinação da superfície do erro (ver item 2.3.6.1); e o segundo, na consideração da curvatura dessa superfície (LIU, 2010).

O algoritmo Levenberg-Marquardt foi desenvolvido para abordar a velocidade de treinamento de segunda ordem sem ter que calcular a matriz hessiana (THE MATHWORKS INC., 2014). Para isso, aproxima a matriz hessiana usando a matriz jacobiana, que pode ser calculada por métodos menos complexos. A sua regra de atualização dos pesos

¹¹ Mínimo local: ponto mínimo de uma função, “um vale”, localizado em alguma região da superfície do erro.

sinápticos foi proposta por Levenberg em 1944 e adaptada por Marquardt em 1963 (MADSEN; NIELSEN; TINGLEFF, 2004), sendo dada pela Equação 9:

$$x_{k+1} = x_k - [J^T - J + \mu I]^{-1} J^T e \quad (9)$$

Onde:

x: vetor de pesos;

J: matriz jacobiana;

J^T : matriz J transposta;

e: erro;

μ : coeficiente de combinação (parâmetro que torna a matriz hessiana definida positiva); e

I: matriz identidade.

Em comparação com o Gradiente Descendente, é um algoritmo mais veloz, mas pode se tornar inviável computacionalmente, no caso de redes com muitas conexões sinápticas (SILVA; ALMEIDA; YAMAKAMI, 2012).

2.3.6.3 Regularização bayesiana

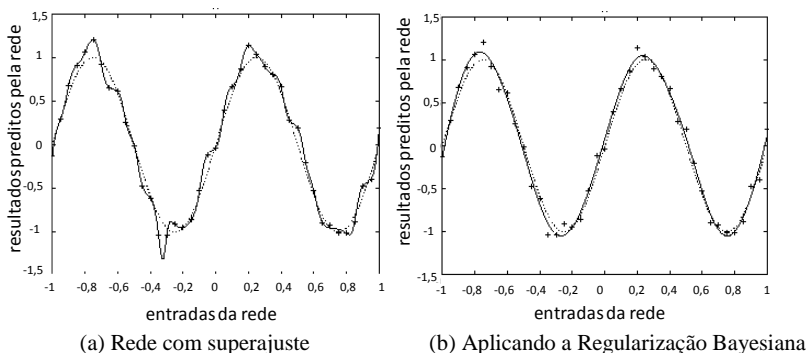
A regularização bayesiana foi proposta por MacKay (MACKAY, 1992); ajusta os pesos sinápticos da rede e os desvios (*bias*) de acordo com Levenberg-Marquardt. O objetivo dessa regra é tentar diminuir os valores dos pesos de forma a ter um melhor comportamento na interpolação. No processo, um termo de regularização é incluído na função objetivo de forma que o algoritmo de estimação faça com que os parâmetros irrelevantes convirjam para zero, reduzindo assim o número de parâmetros efetivos utilizados no processo (RODRIGUES; MACRINI; MONTEIRO, 2008).

Nessa regra, assume-se que os pesos e os desvios (*bias*) da rede são variáveis aleatórias com distribuições especificadas. Os parâmetros de regularização são relacionados com variâncias desconhecidas associadas a essa distribuição e podem ser calculados através de técnicas estatísticas (THE MATHWORKS INC., 2014). Segundo Ferreira (2005), a regra utiliza aproximação gaussiana da probabilidade a *posteriori*, que possibilita a estimativa automática do parâmetro de regularização. Com isso, evita-se a necessidade da utilização de um

conjunto de validação, permitindo que todos os dados sejam empregados para treinamento do modelo.

Os métodos de regularização são utilizados para melhorar a generalização das RNAs e evitar o treinamento excessivo. A Figura 10 ilustra a resposta de uma rede neural que foi treinada para aproximar uma função seno ruidosa. O gráfico da Figura 10a ilustra o resultado de um treinamento em que ocorreu o superajuste e o da Figura 10b, o resultado de um treinamento utilizando a Regularização Bayesiana para evitá-lo.

Figura 10 – Exemplo de aproximação da função seno ruidosa antes e depois da aplicação da Regularização Bayesiana



Fonte: Adaptado de: The Mathwors Inc.(2014).

Como desvantagem, a técnica assume um elevado número de aproximações e hipóteses ao longo do treinamento, muitas delas não podendo ser verificadas em aplicações práticas (FERREIRA, 2005).

2.3.7 Panorama do uso de RNAs aplicadas para a modelagem do comportamento energético de edifícios

Neste item será abordado o estado da arte do uso de RNAs para a modelagem do desempenho energético em edificações. Para tal, introduziu-se o conceito de modelo “caixa-preta” e, então, definiram-se três categorias de aplicações de RNA: I. Modelagem do desempenho energético em edificações, II. Previsão de iluminâncias e III. Outras aplicações relacionadas ao comportamento energético do edifício.

2.3.7.1 *Conceito de modelo “caixa-preta”*

A classificação de modelos matemáticos pode ser feita de acordo com o nível de conhecimento que se tem da sua estrutura, sendo chamados de modelos “caixa-branca”, “caixa-cinza” ou “caixa-preta” (LJUNG, 1987). Os primeiros baseiam-se em princípios físicos, sendo suas estruturas totalmente ajustadas com base em informações conhecidas previamente (informações originárias das leis físicas). Estes modelos, por vezes, apresentam dificuldade na descrição de sistemas de relações complexas. Os modelos “caixa-preta”, por sua vez, não utilizam nenhuma informação conhecida previamente para a definição de sua estrutura. Estes modelos podem ter suas estruturas classificadas em famílias que normalmente apresentam flexibilidade para a modelagem de sistemas. Entretanto, apresentam dificuldades na interpretação dos resultados em termos físicos. Os modelos “caixa-cinza”, ou modelos híbridos, combinam características dos dois anteriores, procurando superar as suas limitações. Estes modelos utilizam algum conhecimento prévio na simplificação dos algoritmos quando da seleção de sua estrutura. O que poderia ser destacado como limitação destes modelos é justamente sua vantagem, pois combinam dois domínios científicos, demandando mais tempo de simulação e maior detalhamento de informações que os denominados “caixa-preta”, mas oferecem menos informações físicas que os modelos “caixa-branca” (CORREA; AGUIRRE, 2004; FOUCQUIER et al., 2013; FUMO, 2014; JACOME, 1996).

Fouquier (2013) fez uma comparação entre as três técnicas sob o enfoque da modelagem do desempenho termoenergético da edificação. Os modelos “caixa-preta”, em que se enquadram as redes neurais artificiais, destacam-se por não necessitarem de uma descrição detalhada da geometria do edifício, precisarem de um grande conjunto de treinamento e pela dificuldade na interpretação dos dados em termos físicos.

2.3.7.2 *Aplicação de RNA para a modelagem do desempenho energético em edificações*

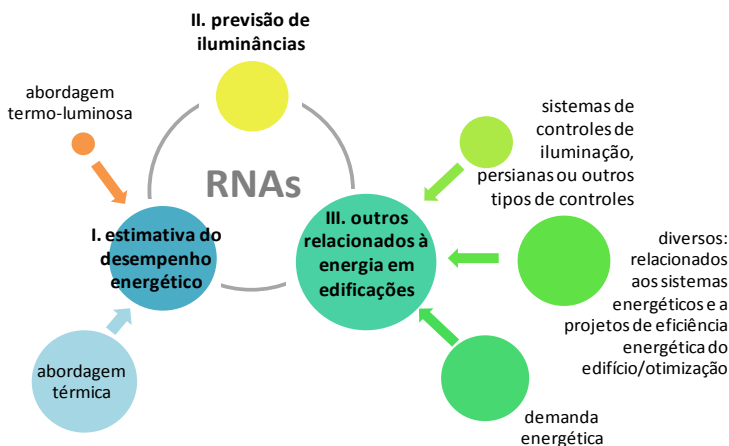
A popularidade das RNAs para modelar o desempenho de edifícios vem crescendo nas últimas décadas. A exemplo disso, quatro trabalhos apresentam um panorama do uso dessa técnica para a modelagem energética de edifícios: i) Kalogirou (2000, 2001) apresenta uma breve revisão de possíveis aplicações de RNA para sistemas de energia renovável; ii) Krarti (2003) apresenta algumas abordagens da

aplicação de inteligência artificial e discute alguns trabalhos pontuais nessa área; e iii) Zhao e Magoulès (2012) oferecem um panorama de métodos de modelagem do consumo energético. Os autores discutem a adoção de métodos elaborados e simplificados, métodos estatísticos e de inteligência artificial. As RNAs foram tratadas como o modelo de inteligência artificial mais difundido para a predição do consumo energético em edifícios e como solução largamente utilizada por cientistas nos últimos 20 anos. Além disso, eles salientam a habilidade desses modelos de resolverem problemas não lineares, o que faz deles potencialmente aplicáveis para a estimativa do consumo energético de edifícios. É importante ressaltar que apenas 12 anos antes, Kalogirou (2000) utilizou alguns poucos exemplos de aplicações de RNA para a predição do consumo energético, enquanto Zhao and Magoulès (2012) apresentaram mais de 50. Esse crescimento pode ser justificado pelos resultados satisfatórios que essa técnica vem apresentando no campo de estudo. Dois anos depois, Ahmad et al. (2014) fizeram uma revisão sobre métodos de inteligência artificial utilizados para estimar o consumo energético em edificações e apontaram as RNAs como as mais difundidas, sugerindo a combinação dessa técnica com outras técnicas através de modelos híbridos. Quanto aos usos híbridos, é crescente o uso de RNA em combinação com algoritmos genéticos (GA), apresentando elevado potencial para agilizar os processos de otimização (EVINS, 2013; NGUYEN; REITER; RIGO, 2014). Ainda em trabalhos de revisão, mas não diretamente sobre RNA, Fumo (2014) apresentou uma revisão sobre os conceitos aplicados para a estimativa de energia do edifício sob o enfoque de edificações residenciais. O autor classificou os métodos como “satisfatórios” ou “bons” de acordo com a bibliografia para as categorias: projeto, medidas de conservação de energia e *retrofit*. As RNAs não foram consideradas aplicáveis para projeto e foram consideradas satisfatórias para as outras duas categorias. Abu Bakar et al. (2015) apresentaram uma visão geral de trabalhos publicados sobre métodos de estimativas e indicadores de eficiência energética, tendo novamente as RNAs recebido destaque entre os métodos de estimativa de consumo energético.

A revisão de literatura sobre redes neurais aplicadas à estimativa de consumo energético considerando a iluminação natural mostrou que os métodos de inteligência artificial estão sendo usados com mais frequência; entretanto, apenas um estudo que aborda diretamente esse assunto foi encontrado. A Figura 11 ilustra a proporção, por meio do tamanho dos círculos, de trabalhos encontrados sobre I. Estimativa do desempenho energético em edificações; II. Previsão de iluminâncias; e

III. Outras aplicações. A primeira categoria foi dividida em trabalhos que só consideram a abordagem térmica e aqueles que consideram a iluminação natural, em que se localiza o único trabalho encontrado, o de Wong, Wan e Lam (2010), que será descrito em detalhe. A terceira categoria foi dividida em demanda energética, sistemas de controle e outros sistemas ou projeto. Demanda energética engloba os casos em que as edificações normalmente estão em uso, podendo utilizar redes com aprendizagem supervisionada em tempo real ou previsão de carga em curto prazo, por exemplo. Sistemas de controle abordam sistemas de automação, na maioria dos casos, de controle de iluminação artificial ou de persianas. Outros sistemas ou projeto abarcam aplicações diversas que podem ser outros sistemas energéticos, como água quente ou sistemas solares, otimização de projetos visando à eficiência energética ou à gestão energética do edifício.

Figura 11 – Distribuição de artigos sobre RNAs encontrados por assunto de interesse deste trabalho



Fonte: Autor.

Quanto ao grupo **I. Estimativa do desempenho energético em edificações**, as mais diversas aplicações de RNA foram observadas, encontraram-se redes baseadas em resultados medidos e simulados (metamodelos), num total de 23 trabalhos (ver Quadro 1). Redes *perceptron* multicamadas alimentadas adiante com algoritmos da retropropagação do erro Gradiente Descendente foram as mais utilizadas para estimativas de consumo energético. Em seguida, as Levenberg-

Marquardt apareceram como alternativa e em menor quantidade as redes recorrentes como as Jordan Elman. Além disso, foram observadas aplicações híbridas com algoritmos genéticos ou lógica *fuzzy* como NDGA-II e GA-ANFIS. Os erros obtidos para a estimativa do consumo energético das redes híbridas variaram de 1% a 4%. Como arquitetura de rede, a grande maioria possuía apenas uma camada intermediária. Os parâmetros de entrada englobaram estação do ano, insolação, temperatura, umidade relativa, radiação solar, espessura de alvenaria e isolamento, função do edifício, hora do dia, orientação, razão de transparência, fator solar, fluxo solar, seção do *brise*, seno, cosseno da hora do dia, ângulos de sobreamento, transmitância e absortância das superfícies, densidade de carga interna, padrão de uso; e parâmetros de saída englobaram consumo energético total anual, horário e PMV, entre outros.

Já para a **II. Previsão de iluminância**, as redes baseiam-se em iluminâncias medidas, sendo as mais utilizadas as de retropropagação do erro, alimentadas adiante com Gradiente Descendente. De acordo com os 10 trabalhos destacados no Quadro 1, foram encontradas redes objetivando saídas relacionadas ao conforto luminoso, à disponibilidade de luz referente a diferentes tipos de céu e a projeto de proteções solares, de forma a garantir determinado nível de iluminância interna. Os parâmetros de entrada englobaram iluminância decorrente da iluminação natural, hora do dia e nível inicial de iluminância artificial, cor do piso, forro, parede interna e cortina, orientação, área de abertura e fator de visão de céu (FCV), data e hora, temperatura externa, radiação solar, umidade, índice UV e dose de UV, distância da janela, número de janelas, orientação dos ambientes, pavimento, dimensões do ambiente e identificação do ponto de medição; e os parâmetros de saída englobaram preferências de usuários de escritório por determinadas quantidades de iluminâncias artificiais, iluminâncias referentes à iluminação natural (para as redes que visavam ao conforto luminoso).

Para as redes que visavam caracterizar a disponibilidade de luz celeste, os parâmetros de entrada foram ângulo de altura solar e condição de céu, temperatura de orvalho, água precipitável, índice de brilho do céu, índice de claridade de Perez e índice de claridade; e os parâmetros de saída englobaram irradiância/iluminância horizontal global e irradiância horizontal difusa e eficácia luminosa. Para os projetos de proteções solares, utilizaram-se ângulo de altura solar, ângulo do azimute solar, iluminância horizontal direta e iluminância horizontal difusa para a obtenção de ângulo ótimo de aletas de persianas.

As redes da categoria **III. Outras aplicações – demanda energética**, descritas nos trabalhos apresentados no Quadro 1, em sua maioria são recorrentes, como as Elman ou autorregressivas (*nonlinear autoregressive with exogenous input – NARX*). Observaram-se redes híbridas com combinações quasi-physical e RNA alimentando outras RNAs. Os erros, em geral, foram inferiores a 5%; entretanto, ocorreram erros de até 10%. Entre os parâmetros de entrada, encontraram-se valores de temperatura do ar e radiação solar, tempo, indicadores econômicos, temperatura máxima, mínima, temperatura média do dia de predição, média do dia anterior ao dia de predição e consumo energético. Como dados de saída, observaram-se demanda energética total, demanda energética anual por aquecimento e resfriamento, demanda energética para edificações em um país, previsão uma hora adiante à intensidade da corrente elétrica, demanda de diferentes usos finais como sistema de ar-condicionado e sistema de ventilação, aparelhos em geral, circuitos de iluminação internos e externos, uso da eletricidade, preço e custo.

Para os **sistemas de controle** e automação, a aplicação de RNA com lógica *fuzzy* é a mais difundida, como as aplicações sistemas de inferência neuro-*fuzzy* adaptativo (ANFIS), por exemplo. Entre as redes, encontraram-se redes alimentadas adiante autoadaptativas e as de funções de base radial (*radial basis function network – RBFN*). Entre os algoritmos, observaram-se aplicações de Levenberg-Marquardt e de redes de crença bayesiana (*baysian belief – BN*). Em usos **diversos**, encontraram-se casos de redes híbridas com algoritmos genéticos para auxílio de tomada de decisão e/ou otimização, não sendo em alguns desses casos utilizada a *clusterização*. Também se observaram aplicações para seleção de variáveis de estudo e usos mais diversos como modelagem de CFD para avaliação de ventilação na eficiência energética e falha no diagnóstico do consumo energético. Nesses casos, encontraram-se redes Gradiente Descendente alimentadas adiante e *Perceptron* Determinístico Recursivo. Os erros chegaram a 20%, mas, como essas redes não convergem exatamente para o foco do estudo, a avaliação do que é um erro baixo é mais complexa, visto que os autores dos estudos julgaram os erros aceitáveis.

Os estudos listados no Quadro 1 foram agrupados segundo as categorias descritas na Figura 11, p. 90 e ordenados cronologicamente. Na terceira coluna, são elencados os 72 trabalhos que utilizaram RNA. Na última coluna, são listados os 35 trabalhos aqui chamados de periféricos. Estes trabalhos não utilizaram RNA, mas estudos que adotaram outra abordagem estatística ou matemática e citaram as RNAs

como uma alternativa, mas, por razões justificadas, optaram por usar outra técnica. Estes artigos foram úteis para observar alternativas às RNAs e, de alguma forma, suas limitações.

Quadro 1 – Trabalhos encontrados na revisão de literatura sobre RNAs, agrupados por assunto de interesse deste trabalho (categorias) em ordem cronológica

Grupo	Subgrupo	Trabalhos/Autores	Periféricos
Estimativa do desempenho energético em edificações	abordagem térmica	Datta e Tassou, 1998; Kalogirou, 2000; Kalogirou e Bojic, 2000; Kalogirou, 2001; Guillemín e Morel, 2002; Krarti, 2003; Neto e Fiorelli, 2008; Yezioro, Dong e Leite, 2008; Ekici e Aksoy, 2009; Magnier e Haghghat, 2010; Li, Su e Chu, 2011; Melo, 2012; Zhao e Magoulès, 2012; Aqlan et al., 2014; Buratti, Barbanera e Palladino, 2014; Coakley, Raftery e Keane, 2014; Fumo, 2014; Lepadatu, Judele e Rosu, 2014; Melo et al., 2014; Yang, Asadi e Geem, 2014; Kalogirou et al., 2015; Lu, Lü e Kibert, 2015; Zhang et al., 2015	Chidiac et al., 2011; De Wilde, 2014; Jung, Kim e Heo, 2015; Paulus, Claridge e Culp, 2015
	abordagem termo-luminosa	Wong, Wan e Lam, 2010	Lo Verso, Pellegrino e Pellerey, 2014; Shen, Hu e Patel, 2014
Previsão de iluminâncias		Çolak e Onaygil, 1999; López e Gueymard, 2007; Pizarro e Souza, 2007; Pattanasethanon et al., 2008; Kazanasmaz, Günaydin e Binol, 2009a; Li et al., 2010; Hu e Olbina, 2011; Janjai e Plaon, 2011; Tfba e Leal, 2012; Colaco et al., 2014	Trobec Lah et al., 2006; Ahmed et al., 2011; Chan e Tzempelikos, 2013
Outras aplicações	demanda energética	Olofsson, Andersson e Östin, 1998; Mihalakakou, Santamouris e Tsangrassoulis, 2002; Ferreira, 2005; González e Zamarreño, 2005; Yang, Rivard e Zmeureanu, 2005; Kavaklioglu et al., 2009; Escrivá-Escrivá et al., 2011; Edwards, New e Parker, 2012; Kouveletsou et al., 2012; Marvuglia e Messineo, 2012; Roldán-Blay et al., 2013; Ahmad et al., 2014; Ardakani e Ardehali, 2014; Zamora-Martínez et al., 2014; Abu Bakar et al., 2015	Jain et al., 2014
	sistemas de controle	Guillemín e Morel, 2001; Dounis e Caraiscos, 2009; Castilla et al., 2010; Tiller et al., 2010; Ferreira et al., 2012; Moon, Yoon e Kim, 2013	Kurian et al., 2008; Kazanasmaz, 2013; Kim e Todorovic, 2013; Logar, Kristl e Skrjanc, 2014
	outros sistemas ou projeto	Chow et al., 2002; Zmeureanu, 2002; Ling e Liu, 2004; Ardehali, Farmad e Adams, 2010; Thirugnanasambandam, Iniyar e Goic, 2010; Ardehali, 2011; Rosiek e Batlles, 2011; Zemella et al., 2011; Congradac e Kulic, 2012; Hong, Koo e Park, 2012; Qin et al., 2012; Rapone e Saro, 2012; Lapinskiene e Martinaitis, 2013; Magoulès, Zhao e Elizondo, 2013; Stevanovic, 2013; Jeong, Koo e Hong, 2014; Machairas, Tsangrassoulis e Axarli, 2014; Yu et al., 2015	Caldas e Norford, 2002; Coley e Schukat, 2002; Wright, Loosemore e Farmani, 2002; Wang, Zmeureanu e Rivard, 2005; Caldas, 2008; Tuhus-Dubrow e Krarti, 2010; Hamdy, Hasan e Siren, 2011; Rakha e Nassar, 2011; Turrin, Von Buelow e Stouffs, 2011; Henriques, Duarte e Leal, 2012; Kolokotsa et al., 2012; Evins, 2013; Hamdy, Hasan e Siren, 2013; Tomazic et al., 2013; Aria e Akbari, 2014; Mavromatidis, Marsault e Lequay, 2014; Nguyen, Reiter e Rigo, 2014; Petri et al., 2014; Shan, 2014; Chang e Shih, 2015

Fonte: Autor.

2.3.7.3 Aplicação de RNA para prever o consumo de energia elétrica em edifícios iluminados naturalmente

Redes neurais artificiais já foram aplicadas para modelar o consumo energético de edifícios considerando a iluminação natural. Wong, Wan e Lam (2010) usaram uma RNA com retropropagação do erro com os seguintes parâmetros de entrada: quatro parâmetros relacionados ao clima (temperatura média diária de bulbo seco, temperatura média diária de bulbo úmido, radiação solar global diária e índice de claridade médio diário), quatro relacionados ao projeto do edifício (abertura solar, abertura de iluminação natural ou abertura efetiva, *brises* horizontais e verticais) e os últimos parâmetros relacionados ao tipo do dia (por exemplo, dias da semana, sábados ou domingos). Como parâmetros de saída, quatro neurônios foram propostos, correspondentes à eletricidade diária utilizada para resfriamento, aquecimento, iluminação e total. O coeficiente de Nash–Sutcliffe utilizado para avaliar a precisão do modelo obtido foi de 0.994, indicando elevado poder de predição. Entretanto, os dados utilizados para treinar a RNA foram simulados no programa EnergyPlus, que, como mostrado no item 2.1.2, p. 63, apresenta limitações quanto ao cálculo da iluminação natural. Além disso, algumas variáveis-chave relacionadas à iluminação natural como profundidade do ambiente, largura, altura ou até mesmo refletância das superfícies e controles do sistema de iluminação não foram contempladas. Apesar de terem considerado a influência de proteções solares externas, consideraram persianas internas automatizadas para evitar ofuscamento, o que se mistura com o efeito dos *brises*, tornando mais difícil a observação do efeito desse parâmetro isoladamente. Como na maioria dos trabalhos, a simulação termoenergética foi feita dividindo uma planta livre em cinco zonas térmicas. Essa configuração apresenta duas limitações significativas para a avaliação da iluminação natural. A primeira é de que o efeito de diferentes orientações pode ser mitigado quando o efeito de uma orientação compensa a outra. A segunda é de que zonas térmicas dificilmente coincidem com zonas luminosas, que são delimitadas por subdivisões dos ambientes. Finalmente, a técnica de amostragem utilizada para experimentos randômicos foi o método de Monte Carlo. Essa técnica foi utilizada para selecionar três casos e avaliar o desempenho do modelo. Entretanto, técnicas de amostragem como o Hipercubo Latino (AHL) podem apresentar melhor desempenho com RNA, possibilitando um estudo mais detalhado (KHAN; LYE; HUSAIN, 2008; MELO, 2012; RISSO; RISSO; SCHIOZER, 2010).

Este estudo é relevante ao passo que define as RNAs como ferramenta para modelar o consumo energético com foco no potencial do aproveitamento da iluminação natural. Entretanto, ainda existe o desafio de investigar as variáveis-chaves que não foram abordadas por Wong, Wan e Lam (2010), fundamentais para a definição da iluminação natural, tais como parâmetros térmicos da envoltória, parâmetros da geometria do ambiente, orientação, localidade e parâmetros de saída de suficiência de iluminação natural. Outro ponto importante a ser desenvolvido é a investigação das limitações das RNAs ante a representação das características fundamentais das variáveis, como, por exemplo, variáveis que operam em diferentes escalas. O principal caso é o da orientação, pois se trata de uma variável que opera em escala polar que, nos estudos encontrados na bibliografia, tem seu efeito mascarado pelo agrupamento de zonas térmicas na simulação computacional.

2.4 CONSIDERAÇÕES FINAIS DO CAPÍTULO DE REVISÃO BIBLIOGRÁFICA

Esta revisão de literatura abordou a iluminação natural de maneira geral, destacando-se o potencial do seu aproveitamento com vistas à eficiência energética; levantou métodos simplificados para a sua avaliação; e apresentou os conceitos da técnica de RNAs, bem como as pesquisas desenvolvidas na área.

Inicialmente, discutiram-se os benefícios quantitativos e qualitativos atribuídos ao aproveitamento da iluminação natural em edificações, bem como a preferência dos usuários por ambientes iluminados naturalmente. Ressaltou-se a importância de a iluminação natural ser adotada como princípio projetual já nas fases de concepção do projeto. Geometria dos espaços, forma, distribuição e tamanho das aberturas, propriedades das superfícies, características dos vidros e sistemas de controle tanto de iluminação natural quanto artificial foram enumerados como variáveis de fundamental importância para a determinação de um ambiente bem iluminado.

A integração dos sistemas de iluminação natural e de iluminação artificial foi abordada sob o enfoque energético e qualitativo, evidenciando-se as suas funções principais.

Foram apresentadas medidas de iluminação, apontando-se as medidas dinâmicas como as mais adequadas para estimar quantitativamente a iluminação natural e integrá-la a avaliações termoenergéticas. Essas medidas são verificadas através de simulação computacional; nesse contexto, apresentaram-se as vantagens e as

desvantagens dos tipos de simulações (estáticas e dinâmicas), bem como dos métodos matemáticos utilizados para o cálculo da iluminação. Debateram-se a complexidade da utilização da simulação computacional detalhada durante o processo de projeto e a aplicabilidade de métodos simplificados para a verificação de desempenho de diferentes soluções arquitetônicas.

Dentre os inúmeros métodos simplificados desenvolvidos para auxiliar o arquiteto no projeto de soluções de iluminação natural, foram levantados 72 e classificados segundo a TASK 21 da IEA (2000). As RNAs apresentaram expressivo potencial para a modelagem do consumo energético atribuído ao aproveitamento global da iluminação natural (sistemas de iluminação artificial e condicionamento de ar), baseado em simulações energéticas através de metamodelagem. A aplicação de metamodelos como método simplificado possibilita resposta rápida, visto que se baseia em casos pré-simulados. As principais vantagens do uso de RNAs são (i) a representação de funções não lineares e (ii) o seu poder de generalização.

No levantamento dos estudos envolvendo RNAs para a modelagem da iluminação natural e do comportamento energético dos edifícios, verificou-se que, na maioria deles, as RNAs conseguiram aproximar os resultados de forma satisfatória, apresentando erros considerados aceitáveis pelos respectivos autores.

A maior parte dos estudos encontrados que modelaram o fenômeno da iluminação natural o fizeram abordando a predição de iluminâncias. O conjunto de dados foi adquirido com base em medições; e os resultados obtidos indicaram a capacidade das RNAs de representarem o fenômeno. Os estudos relacionados ao desempenho energético tiveram seus conjuntos de dados adquiridos através de medições ou simulações computacionais detalhadas. Os casos baseados em simulação indicaram aplicabilidade da ferramenta para a metamodelagem.

O único estudo encontrado direcionado para a modelagem do consumo energético tendo como foco o desempenho da iluminação natural foi o de Wong, Wan e Lam (2010). Entretanto, esse estudo apresenta algumas limitações, como as listadas abaixo.

- Não considera algumas variáveis-chave importantes como profundidade, largura, altura do ambiente e refletância das superfícies.
- Simulação computacional termoenergética baseada no EnergyPlus, que apresenta distorções ao calcular a

iluminação natural, como apresentado no item 2.1.2, p. 63.

- Mitigação do efeito da orientação através do agrupamento das zonas térmicas e da localização de aberturas e de todas as fachadas.
- Mitigação do efeito de proteções solares ao considerá-las em combinação com persianas internas automáticas que operam em função de critério de ofuscamento.
- Predição de consumo energético diário (não permite averiguar se uma única rede seria capaz de modelar os efeitos da sazonalidade inerente ao consumo anual).
- Consideração de apenas uma localidade geográfica.
- Não explora parâmetros de desempenho de iluminação natural, como, por exemplo, a autonomia da iluminação natural ou iluminâncias úteis.

Com base no que foi apresentado neste capítulo, as RNAs se apresentaram como ferramentas em potencial para serem utilizadas nas fases iniciais de projeto para a avaliação de diferentes soluções de iluminação natural, inclusive para avaliar viabilidade econômica de implantação dessas soluções. Entretanto, como já mencionado, as limitações e as potencialidades dessa ferramenta ante o fenômeno da iluminação natural e seu impacto no consumo energético devem ser investigadas a fim de possibilitar uma aplicação consistente. Os estudos acessados abordaram aplicações de RNA, mas não uma investigação de suas possibilidades para representar o fenômeno da iluminação natural.

Em linhas gerais, esta investigação pode ser feita através de estudos sistemáticos ou de estudos paramétricos utilizando técnicas de amostragem. Contudo, independentemente da abordagem, deve ser pautada pela relação das variáveis-chave que influenciam o fenômeno da luz natural.

Diante do exposto, esta pesquisa visa contribuir para o entendimento mais aprofundado da aplicação da técnica de RNA para aproximar o fenômeno da iluminação natural e seu impacto no consumo energético de edificações não residenciais.

3. MÉTODO

Este capítulo aborda o método geral da pesquisa; entretanto, cada um dos capítulos seguintes apresenta um detalhamento do método geral aplicado ao propósito do estudo aprofundado no respectivo capítulo.

O método geral baseia-se em uma avaliação sistemática iniciada com as perguntas estruturais de pesquisa; os resultados gerados para responder a essas perguntas motivaram novas perguntas. As perguntas foram elaboradas conforme as particularidades das variáveis-chave de iluminação natural e da própria estrutura das RNAs. A metamodelagem da iluminação natural sob o enfoque da conservação de energia elétrica utilizou RNAs treinadas com dados provenientes de simulações energéticas. Assim, buscou-se destacar as possibilidades e as limitações desse tipo de modelagem estatística para o estudo da iluminação natural.

A pesquisa apresenta caráter investigativo; entretanto, no Capítulo 8 adota-se um caráter propositivo. Como a proposta do Capítulo 8 combina uma rede neural elaborada de acordo com o método geral com um zoneamento de iluminação natural, optou-se por descrever o método adotado para o zoneamento no próprio capítulo.

3.1 ABORDAGEM SISTEMÁTICA DA PESQUISA

A abordagem sistemática caracteriza-se por um conjunto de passos organizados cujos resultados são utilizados como entrada ou geração do questionamento seguinte, que originará o próximo passo. A evolução desse processo permite o aprofundamento na investigação proposta (ANDRADE et al., 2006). Ao fim de cada passo, o pensamento reflexivo permite observar, analisar, concluir e definir o próximo passo baseando-se nos significados obtidos (COSTA, 2003). Esse método também é conhecido como Investigação-Ação (COSTA, 2003; TRIPP, 2005).

No campo da administração, a abordagem sistemática é bastante difundida, em especial na intervenção organizacional. Segundo Sellitto (2005), de modo geral, a abordagem pode ser apresentada em três blocos:

- (i) fazer a leitura da situação atual;
- (ii) diagnosticar o que contribuiu para gerar a situação atual; e
- (iii) propor planos de trabalho para avançar a partir da situação atual.

Neste trabalho, essa abordagem foi aplicada na condução da investigação de forma que os blocos (i) e (ii) permitiram formular

perguntas de pesquisa e definir a ação metodológica, e que o bloco (iii) permitiu, a partir da análise dos resultados, formular a próxima pergunta. É importante salientar que, diferentemente das abordagens tradicionais de investigação-ação, em que a intervenção no passo seguinte é sempre uma busca de melhora do resultado, o foco deste trabalho foi avançar na formulação de um panorama sobre as potencialidades das RNAs para modelar a iluminação natural e não obter uma RNA ideal. Sendo assim, procurou-se sempre testar os limites das redes neurais, inclusive forçando-as a falharem.

Como descrito no item 2.3.7.1, p. 88, as RNAs são modelos “caixa-preta”, o que torna a análise dos seus resultados sob o enfoque físico mais complexa (FOUCQUIER et al., 2013). A proposta de aplicação do método sistemático visou à manipulação das principais variáveis-chave da iluminação natural e dos parâmetros das redes neurais. Para evitar erros de interpretação devido a resultados espúrios do desempenho das redes e obter tendências de comportamento do modelo diante dessas manipulações, para cada teste realizado utilizou-se um conjunto de redes. A investigação sistemática desenvolvida visou mapear as respostas das redes neurais sob o ponto de vista do projetista.

A Figura 12 ilustra as etapas metodológicas desta pesquisa: a etapa 1 – *Definição das perguntas de pesquisa* e a etapa 2 – *Identificação das possíveis limitações das RNAs* atendem aos blocos (i) e (ii) propostos por Selitto (2005); e a etapa 3 – *Definição das ações realizadas para responder às perguntas de pesquisa* atende ao bloco (iii). Essa figura ainda destaca as cinco subetapas da etapa 3, que viabilizaram responder às perguntas por meio de ações determinadas ao longo do trabalho. As cinco subetapas são: *A – Definição das variáveis-chave*; *B – Amostragem do conjunto*; *C – Simulação energética computacional*; *D – Metamodelagem (RNAs)*; e *E – Análise de desempenho dos metamodelos*. A figura que destaca as cinco subetapas será apresentada no início de cada capítulo no método detalhado, atualizada conforme a aplicação no referido capítulo.

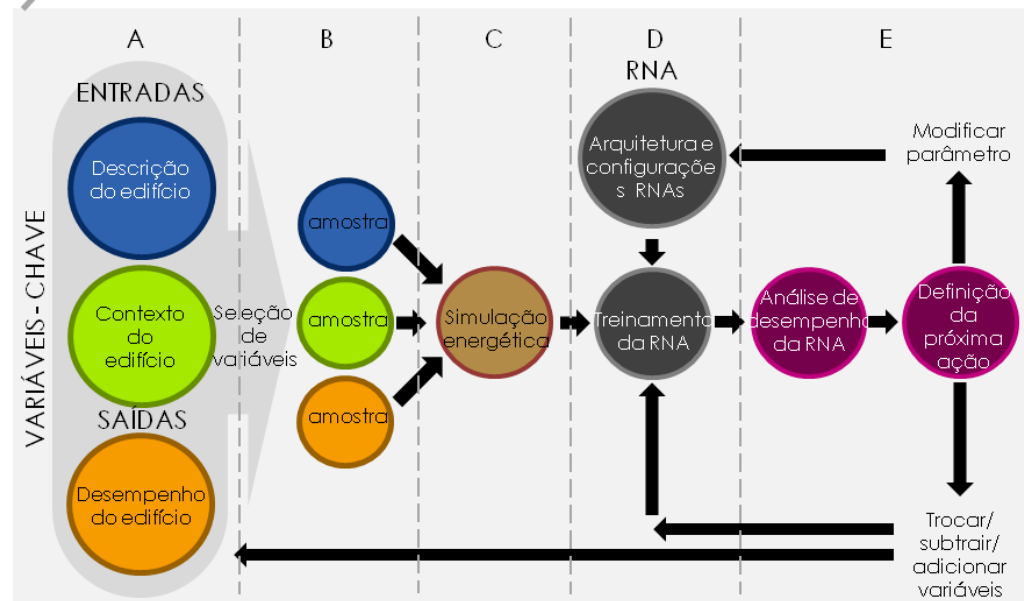
Figura 12 – Esquema das etapas metodológicas da pesquisa (base para quadro resumo dos resultados – disponível no APÊNDICE G)

Capítulo	ETAPA 1- Definição das perguntas estruturais de pesquisa	ETAPA 2 - Identificação das possíveis limitações da aplicação das RNAs (perguntas específicas)				ETAPA 3 - Definição das ações realizadas para responder as perguntas de pesquisa das etapas 1 e 2						Resposta das perguntas ETAPA 2	Resposta das perguntas ETAPA 1	Conclusão geral da tese	
		Conjunto de dados	Padrões de entrada (variáveis-chave ILN)	Arquitetura e configuração da rede	Padrões de saída (variáveis-chave ILN)	Itens do tese e.n que são realizadas ações.	Sub-etapas do método e ferramentas envolvidas								Resultado da ação
							A – definição das variáveis-chave	B – amostragem	C – simulação energética	D – meta-modelagem RNA	E- análise de desempenho				
4	xxx		1-xxx			4.3.1 xxx	xxx	xxx		xxx	xxx	xxx	xxx	xxx	
5	xxx				1-xxx	5.3.1 xxx Ação 1:xxx				xxxx	xxxx	xxx	xxx		
6	xxx			1-xxx		6.3.1 xxx Ação 1:xxx		xxx	xxx	xxx	xxx	xxx	xxx		
7	xxx	1-xxx				7.3.1 xxx Ação 1:xxx			xxx		xxx	xxx	xxx		

Legenda:

xxx: perguntas, ações e respostas; e

⋮ : indicação de sequência, dependerá da quantidade de perguntas e ações.



Fonte: Autor.

3.2 DEFINIÇÃO DAS PERGUNTAS ESTRUTURAIS DE PESQUISA (ETAPA 1)

A análise sistemática sobre a predição da iluminação natural através de redes neurais artificiais norteou-se por perguntas de pesquisa elaboradas a partir de lacunas encontradas na revisão bibliográfica. Logo, o primeiro passo adotado em cada capítulo que discute essa avaliação foi buscar respostas para essas perguntas (etapa 1 da Figura 12). As perguntas apresentadas a seguir são as perguntas estruturais que deram origem aos Capítulos 4, 5, 6 e 7, respectivamente.

- Qual é o potencial das redes neurais artificiais quando comparadas à difundida regressão linear multivariada para modelar a influência da iluminação natural no consumo energético, ao considerar o nível dos ambientes da edificação (cada zona termoluminosa individualmente)?
- Como as redes neurais podem responder à influência da variável orientação que opera em escala polar e é significativa na consideração individual de zonas termoluminosas?
- Como as redes neurais podem responder às variáveis do contexto do edifício, tais como clima e localização, considerando-se apenas poucas variáveis e de fácil obtenção?
- Como as redes neurais podem responder à previsão das variáveis de desempenho do edifício de diferentes naturezas, tais como parâmetros de iluminação natural e de consumo de energia?

A partir dessas perguntas, foram elaboradas outras mais específicas com o objetivo de se obter um panorama das potencialidades e das limitações das neurais (etapa 2 da Figura 12).

3.3 IDENTIFICAÇÃO DAS POSSÍVEIS LIMITAÇÕES DA APLICAÇÃO DE RNAs PARA MODELAGEM DA ILUMINAÇÃO NATURAL (ETAPA 2)

As perguntas elaboradas na etapa 2 do método foram estruturadas segundo as particularidades dos conjuntos de dados a serem avaliados. Esses conjuntos são decorrentes dos padrões de entrada e de saída das redes, definidos de acordo com as variáveis-chave de iluminação natural que a serem abordadas. Além do conjunto de dados, diferentes

possibilidades de arquitetura e configurações de RNAs foram investigadas.

As perguntas da etapa 2, bem como as ações determinadas para respondê-las serão apresentadas no item de método específico de cada capítulo.

3.3.1 Definição das variáveis-chave da iluminação natural para a eficiência energética

A definição das variáveis-chave da iluminação natural sob o enfoque da sua influência no consumo energético considerou a sua influência no sistema de iluminação artificial e no balanço térmico da edificação.

O quadro proposto pelo Comitê de Iluminação Natural, apresentado na Figura 3, p. 61, foi utilizado para respaldar a escolha das variáveis-chave. A partir dele, foram selecionadas algumas variáveis, abordadas neste trabalho de acordo com a seguinte classificação: variáveis da descrição do edifício (*A – descrição completa do espaço tridimensional*, *B – descrição das propriedades das aberturas* e *F – interações com outros sistemas da edificação* da Figura 3), do contexto do edifício (*C – dados climáticos locais* e *D – contexto exterior* da Figura 3) e do desempenho do edifício (*1 – conforto humano* e *2 – impacto energético* da Figura 3). Variáveis do *E – comportamento do usuário* apresentadas na mesma figura não foram abordadas. As variáveis adotadas serão apresentadas no método específico de cada capítulo. Essa classificação e a escolha das variáveis foram estabelecidas a fim de possibilitar a resposta às perguntas de pesquisa apresentadas no item anterior.

Os valores mínimos e máximos de cada variável, tanto de entrada quanto de saída, foram escolhidos evitando que a RNA precisasse extrapolar. A quantidade de exemplos de cada variável foi definida em função do direcionamento da pesquisa.

3.3.2 Identificação dos pontos críticos da arquitetura e da configuração das RNAs para o seu desempenho

Como apresentado no item 2.3, o desempenho das RNAs depende diretamente de sua configuração: da definição do conjunto de dados; dos padrões de entrada e saída; da função ativação/transfêrencia (ver item 2.3.1 da Figura 5); do tipo de arquitetura da rede (ver item 2.3.2); do processo de aprendizagem (ver item 2.3.4); do algoritmo de

aprendizagem (ver item 2.3.6 da Figura 9); e da regra de aprendizagem (ver itens 2.3.6.1, 2.3.6.2 e 2.3.6.3).

Para as avaliações das redes diante dos conjuntos de dados, foram testados aspectos quanto à quantidade de exemplos de cada variável-chave; ao tamanho das amostras de combinações paramétricas; à adequabilidade da seleção de variáveis-chave para o conjunto; à composição de conjuntos de treinamento; à validação (quando aplicável) e ao teste; e ao método para testar o desempenho da rede.

Para as avaliações ante os padrões de entrada e saída, testaram-se a metamodalagem de variáveis que operam em diferentes escalas; a forma de apresentação das variáveis-chave fisicamente correlacionadas; intervalos de variação de diferentes variáveis-chave conforme a complexidade de sua metamodelagem; a adequabilidade da variável escolhida para representar o fenômeno; agrupamentos de variáveis; a metamodelagem de variáveis de diferentes naturezas; e a interinfluência entre variáveis-chave das redes.

Por fim, para as avaliações da arquitetura das redes, testaram-se diferentes funções de transferência; a quantidade de camadas internas e de neurônios nessas camadas; diferentes tamanhos e composições de redes conforme o que se iria modelar; e diferentes regras de aprendizagem.

3.4 DEFINIÇÃO DAS AÇÕES REALIZADAS PARA RESPONDER ÀS PERGUNTAS DE PESQUISA (ETAPA 3)

Como destacado na Figura 12, a etapa 3 do método compreende cinco subetapas, que viabilizaram responder às perguntas de pesquisa. A primeira subetapa, *A – Definição das variáveis-chave*, se deu conforme já descrito no item 3.3.1. O método geral aplicado a cada uma das outras quatro subetapas será descrito a seguir.

3.4.1 Parametrização e amostragem do conjunto

O treinamento, a validação e o teste das redes neurais artificiais exigem um conjunto de dados de exemplos para que a rede possa aprender e generalizar. Esse conjunto foi estabelecido através da combinação entre as variáveis-chave, gerando modelos paramétricos. A amostragem desses modelos, referentes à subetapa *B – Amostragem do conjunto*, se deu de duas maneiras:

- amostragem direcionada para os Capítulos 5 e 6, referentes à avaliação considerando os parâmetros de descrição e do contexto do edifício. As variáveis-chave

foram escolhidas pontualmente conforme a pergunta norteadora da investigação. Nesse caso, a modelagem paramétrica para a simulação foi feita através de uma macro em planilha Excel, adaptada de Westphal (2012), que combina as variáveis, monta arquivos *.idf do EnergyPlus, aciona as simulações e grava os seus resultados; e

- amostragem aleatória para os Capítulos 7 e 8, referentes à avaliação dos parâmetros de descrição e do desempenho do edifício e à proposição do exemplo de aplicação. Adotaram-se a amostragem por Hipercubo Latino, através do programa MATLAB (THE MATHWORKS INC, 2011a), e a modelagem paramétrica, através do Grasshopper (DAVIDSON, 2014) *plug-in* do programa Rhinoceros (MCNEEL; ASSOCIATES, 2014).

Essa diferenciação se fez necessária, pois, para a avaliação sistemática de parâmetros do desempenho da edificação, optou-se por aumentar a quantidade de variáveis-chave de entrada, objetivando obter uma maior variedade de resultados nos parâmetros de saída (de desempenho) da rede neural. Essa alteração conceitual resultou em um número demasiadamente grande de simulações. Logo, para viabilizar a simulação dos casos, a amostragem aleatória das combinações foi a solução adotada.

Entre as possíveis formas de amostragem aleatória, o método de Monte Carlo é o mais difundido. Nesse método, são realizados sorteios aleatórios baseados na distribuição das probabilidades. Entretanto, para o treinamento de RNAs, é importante garantir que pelo menos um exemplo de cada valor de cada variável contido na amostra seja visto pela rede. Dessa forma, optou-se pelo uso da Amostragem por Hipercubo Latino (ALH).

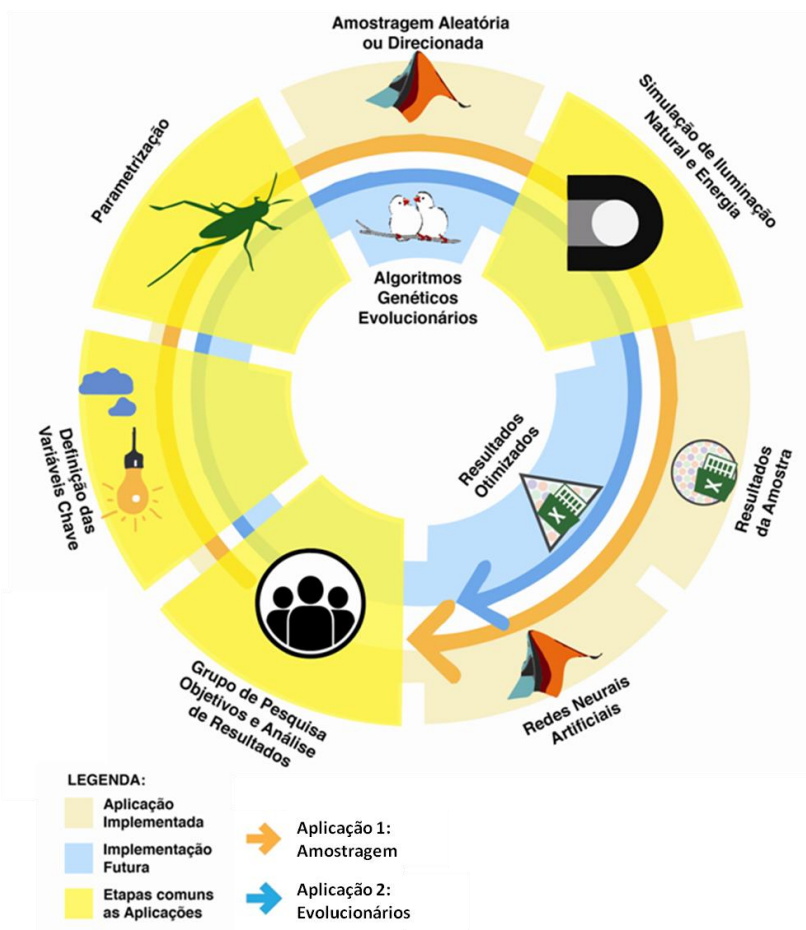
O Hipercubo Latino é uma aplicação do método de Monte Carlo. A diferença básica entre os métodos consiste na maneira como os ensaios são realizados. Para a ALH, apesar de os sorteios também serem aleatórios, esses se dão dentro das faixas previamente definidas (MASCHIO; CARVALHO; SCHIOZES, 2009). Assim, a ALH mostra-se mais adequada, garantindo exemplos para a rede neural provenientes de todas as faixas e na mesma proporção. Outros autores já aplicaram essa técnica de amostragem para a alimentação de redes neurais, tais como Risso, Risso e Schiozer (2010), Queipo et al. (2002) e Zerpa et al. (2005) na área do petróleo. Mais recentemente, Melo (2012) também o

fez na área de eficiência energética em edificações, baseada inclusive em modelos de edificações gerados através de simulações termoenergéticas.

A amostragem por Hipercubo Latino foi feita através de *script* adaptado de Minasny (2004), disponível no sítio do MATLAB (THE MATHWORKS INC, 2014), na central dos usuários em que arquivos podem ser disponibilizados e avaliados. Para a interação entre os programas MATLAB e Grasshopper, os resultados das amostragens feitas no MATLAB foram exportados em arquivo de valores separados por vírgulas (*.csv). O algoritmo de parametrização proposto no Grasshopper foi elaborado de forma a ler esse arquivo e realizar as simulações em lotes. Cada linha do arquivo corresponde a um modelo. Todas as variáveis da população foram previamente programadas no algoritmo do Grasshopper a fim de possibilitar a geração dos modelos paramétricos quando a lista amostrada fosse lida. Dessa forma, o algoritmo poderia ler diferentes amostras dessa mesma população.

A Figura 13 ilustra a concepção da simulação parametrizada idealizada para viabilizar simulações de conjuntos amostrados aleatoriamente ou de forma direcionada; ou para a otimização evolucionária. A seta alaranjada destaca a aplicação implementada no escopo desta pesquisa, representada pela sequência: pesquisador seleciona as variáveis-chave de iluminação natural a serem estudadas; as variáveis são parametrizadas através de algoritmo do Grasshopper; os casos a serem simulados são amostrados; a simulação integrada é realizada por meio do *plug-in* DIVA (SOLEMMA LLC, 2014) do programa Rhinoceros; e os resultados são exportados em planilha Excel e utilizados para o treinamento das RNAs. A seta azul destaca uma aplicação futura do conceito, que foi concebido pensando na utilização do pacote parametrizado para futuros desdobramentos do trabalho utilizando algoritmos genéticos evolucionários. A principal diferença entre as duas abordagens é de que na primeira objetiva-se gerar um conjunto variado e homoganeamente distribuído de casos para o treinamento das RNAs; e de que na segunda parte-se dessa mesma variedade de casos, mas para chegar a um caso de melhor desempenho de acordo com determinados objetivos, como, por exemplo, menor consumo e maior área naturalmente iluminada.

Figura 13 – Esquema conceitual da simulação parametrizada



Fonte: Autor.

3.4.2 Simulação energética computacional

A simulação dos conjuntos de dados, abordada na subetapa C – *Simulação energética computacional*, se deu de três formas, de acordo com os objetivos principais da investigação:

- nos Capítulos 5 e 6, referentes à avaliação considerando os parâmetros de descrição e do contexto do edifício, utilizou-se a simulação termoenergética do EnergyPlus (D.O.E-US, 2012), levando em conta a

iluminação natural pelo método do fluxo dividido (*objeto:Daylighting:Controls*). Neste trabalho será chamada de simulação energética;

- nos Capítulos 7 e 8 referentes à avaliação, considerando os parâmetros do desempenho do edifício e o exemplo de aplicação de RNAs, utilizou-se a simulação integrada. Para essa simulação, adotou-se o *plug-in* DIVA (SOLEMMMA LLC, 2014) do programa Rhinoceros (MCNEEL; ASSOCIATES, 2014), que integra o Daysim-Radiance (REINHART, 2012) e o EnergyPlus v. 7.2 (D.O.E -US, 2012) para uma zona térmica; e
- no capítulo em que é proposto um exemplo de aplicação, Capítulo 8, adotou-se a simulação de iluminação natural no Daysim-Radiance.

Essa diferenciação foi feita em função do tempo e da necessidade de precisão das simulações. Como mencionado no item 2.1.2, p. 63 da revisão bibliográfica, o programa EnergyPlus possui limitações para a modelagem da iluminação natural, mas suas simulações são significativamente mais rápidas; por outro lado, a simulação integrada é mais precisa, mas exige maior esforço computacional. Dessa forma, para os Capítulos 5 e 6, nos quais o principal foco foi avaliar o potencial das redes neurais para prever a influência de variações dos padrões de entrada, optou-se por priorizar a velocidade de simulações. Nessa etapa da investigação, julgou-se mais importante testar várias configurações das próprias redes neurais. Como as avaliações foram comparativas e todas as simulações energéticas foram feitas sob as mesmas condições, aceitou-se a imprecisão inerente ao EnergyPlus.

Já para as avaliações quanto aos parâmetros de desempenho do edifício em que os dados de saída foram avaliados, julgou-se importante trabalhar com maior precisão os efeitos da iluminação natural. Nesse caso, também foram adicionadas variáveis mais complexas da geometria da edificação, como proteções solares, que exigem maior refinamento do programa.

Para o exemplo de aplicação do Capítulo 8, utilizou-se uma rede neural baseada em simulação integrada. Para a proposta do zoneamento de disponibilidade de iluminação natural, utilizou-se o programa Daysim-Radiance, pois não havia a necessidade de simulação termoenergética.

Esse equilíbrio entre tempo de simulação e precisão foi fundamental para viabilizar todos os testes que se pretendiam executar

no trabalho. Informações mais detalhadas quanto aos parâmetros de simulação adotados em cada capítulo foram abordadas nos respectivos itens de detalhamento do método.

Mais informações sobre os programas de simulação utilizados foram disponibilizadas no APÊNDICE B – Resumo das ferramentas utilizadas neste trabalho, p. 419.

3.4.3 Geração dos metamodelos e análise de desempenho

Na subetapa *D – Metamodelagem* utilizaram-se redes neurais artificiais treinadas, validadas e testadas com um conjunto de dados (exemplos) obtidos através das simulações energéticas ou integradas. A avaliação dos metamodelos se deu na subetapa *E – Análise de desempenho dos metamodelos*.

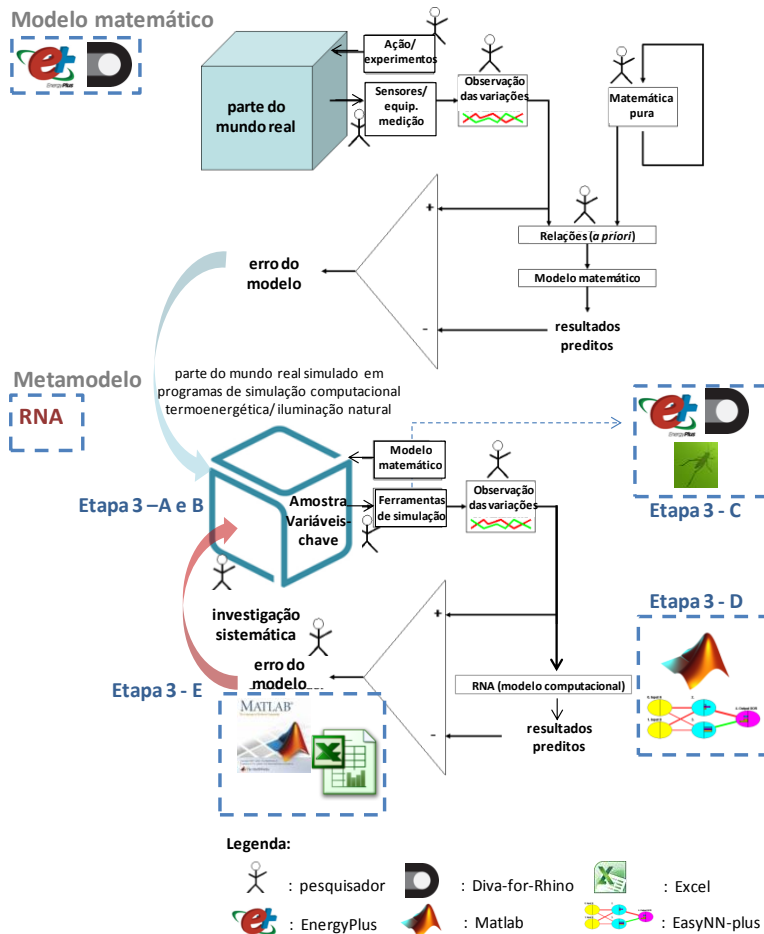
A Figura 14 ilustra o conceito da metamodelagem (ou modelos substitutos) utilizada nesta pesquisa, fazendo um paralelo com a modelagem matemática. Nela foram relacionadas as etapas do método apresentadas na Figura 12. Na parte superior da figura salienta-se o processo de definição de um modelo matemático. No caso deste trabalho, os modelos matemáticos são os modelos utilizados pelos programas-base da simulação termoenergética e de iluminação natural: EnergyPlus e Daysim-Radiance (DIVA e Grasshopper).

Na parte inferior da figura descreve-se o processo de avaliação das redes neurais artificiais, nesse caso um metamodelo. O cubo azul simboliza uma amostra de todas as combinações paramétricas possíveis simuladas através das simulações energéticas ou integradas. Os resultados dessas simulações são avaliados pelo pesquisador; e redes neurais artificiais são propostas. As redes são treinadas, validadas e testadas. O erro da predição da rede é calculado comparando-se o resultado previsto pela rede com os resultados simulados pelas ferramentas de modelagem matemática. Através da análise dos erros, define-se qual será o próximo passo da investigação. Se o erro for baixo, inferior a 5%, entende-se que a RNA foi capaz de modelar aquelas variáveis-chave, caso seja alto, experimentam-se novas alternativas, sempre procurando chegar ao limite da rede. Esta abordagem visou verificar a partir de que situação as redes passariam a falhar. Quando necessário, novas amostras são determinadas e o processo se repete.

A principal diferença entre a primeira e a segunda parte da figura é que o modelo matemático é proposto com base em observações e experimentos reais, ao passo que, na segunda metade, a validação do

modelo é feita com base em resultados obtidos através dos outros modelos, no caso os modelos matemáticos.

Figura 14 – Conceito da metamodelagem utilizada (Etapa 3 da Figura 12)



Fonte: Adaptado de: e-book-mathematical-model (YAHIAOUI; DIAS, 2014).

Para a geração das redes neurais, utilizaram-se dois programas: o MATLAB e o EasyNN-plus. A escolha dos programas objetivou a praticidade nos testes e a possibilidade de programação. O MATLAB é um programa bastante consolidado e utilizado para proposições de RNAs através do pacote de ferramentas *ANN toolboxes*. O programa

apresenta vantagens de possuir diversos formatos de exportação de arquivos, facilitando a interface com outros programas e a possibilidade de programação de diversos tipos de redes neurais. Por sua vez, uma maior liberdade de programação também exige uma maior dedicação à proposição da escrita do código. Já o programa EasyNN-plus, apesar de mais limitado, apresenta interface simplificada e amigável, além de ferramentas úteis como indicação do número de neurônios na camada oculta para determinada configuração de rede. O programa apresenta a opção de programação, mas, como não foi projetado para tal, essa opção é mais limitada que a do MATLAB.

Assim, optou-se pelo uso do EasyNN-plus para testes mais básicos, em conjunto com o MATLAB para testes mais elaborados. Essa abordagem permitiu que fosse realizado um maior número de testes, visto que alguns testes eliminatórios foram realizados no EasyNN-plus e o refinamento, no MATLAB.

Para a criação das redes neurais, foram adotados os seguintes passos: definição dos padrões, inicialização da rede, definição dos parâmetros de treinamento, treinamento da rede e teste da rede.

A definição dos padrões se deu conforme a investigação a ser realizada e foi descrita em cada ação do método específico de cada capítulo. Consistiu em importação do conjunto de dados, definição dos vetores de entrada e saída, modo de apresentação da variável (por exemplo, binária, real etc.) e modo de apresentação dos dados à rede: se em ordem ou aleatoriamente.

A inicialização da rede deu-se pela normalização do conjunto de dados, pela programação da gravação e pela exportação dos resultados. Este último apenas para o MATLAB, visto que no EasyNN-plus a exportação dos dados é uma função implementada e as opções de exportação ficam disponíveis depois do treinamento da rede.

Em seguida, definiram-se os métodos de treinamento e, conseqüentemente, a forma de dividir o conjunto de dados em treinamento, validação e teste. Decidiram-se a função ativação/transfêrencia; o tipo de arquitetura da rede; o processo de aprendizagem; o algoritmo de aprendizagem; e a regra de aprendizagem.

Os métodos de treinamento adotados foram o múltiplo treinamento de um mesmo conjunto dividido aleatoriamente em percentuais para treinamento e teste, denominado aqui de abordagem da literatura; e a validação cruzada. A opção por trabalhar com treinamento múltiplo visou à observação de tendências de desempenho das redes, visto que o objetivo deste trabalho foi avaliar as potencialidades e as

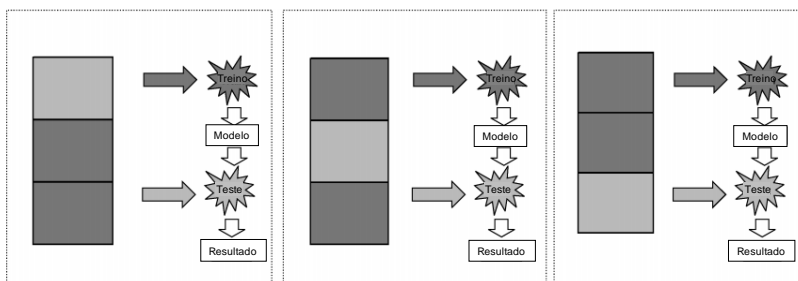
limitações das redes neurais para modelar os efeitos da iluminação natural no consumo energético, e não propor uma rede neural eficiente.

No primeiro caso, os conjuntos foram divididos em 80% dos dados para treinamento e 20% para teste. Quando aplicável o conjunto de validação, selecionou-se entre 10% e 20% dos dados do conjunto de treinamento para validá-lo. Nesse caso, a seleção dos conjuntos de treino, validação e teste foi feita somente uma vez. O que mudou para cada treinamento foi o ponto da superfície do erro em que se iniciavam os passos em direção à minimização do erro (selecionado de forma aleatória) e, com isso, a inicialização dos pesos sinápticos. Neste trabalho, treinaram-se de 3 a 10 redes neurais para cada investigação.

No método da validação cruzada *multi-fold*, o conjunto de dados é dividido em dois subconjuntos. O primeiro é o subconjunto de treinamento e consiste nos exemplos apresentados à rede. E o segundo é o subconjunto teste. O subconjunto teste tem 10% a 20% do conjunto de treinamento.

O conjunto de dados original de N exemplos é, então, dividido em K subconjuntos, onde $K > 1$. O treinamento do modelo ocorre em todos os subconjuntos, exceto em um, e o erro de validação é medido testando-o sobre o subconjunto deixado de fora. O procedimento descrito é repetido por K tentativas, cada vez utilizando um subconjunto de teste diferente (HAYKIN, 2001). A Figura 15 ilustra o procedimento de um conjunto com $K = 3$ tentativas.

Figura 15 – Esquema da Validação Cruzada com $K = 3$ tentativas



Fonte: Adaptado de: Refaeilzadeh, Tang e Liu (2008).

Para o presente trabalho, foram realizadas $K = 10$ tentativas, pois, de acordo com Refaeilzadeh, Tang e Liu (2008), esse número permite previsões usando 90% dos dados, tornando a rede mais apta a generalizar o conjunto de dados completo. Logo, para o conjunto de

testes foram adotados 10% dos dados. A seleção de dados para cada subconjunto foi feita de forma randômica. Este método é especialmente útil para conjuntos de dados com um número relativamente pequeno de casos para o treinamento de RNA.

Como função ativação ou de transferência (de neurônio para neurônio, aplicada ao net^{12}), testaram-se as funções linear, logarítmica-sigmoidal ($logsig^{13}$) e tangente-sigmoidal ($tansig^{14}$) devido a sua grande aplicabilidade (DUCH; JANKOWSKI, 1997; THE MATHWORKS INC., 2014). Essas funções requerem a normalização dos dados de entrada da rede, limitando-se entre 0 e 1 para logarítmica-sigmoidal (ver Equação 10) e entre -1 e 1 para tangente-sigmoidal e linear (ver Equação 11) (MATOS, 2012).

$$\left(z_i^k\right)_n = \frac{z_i^k - z_{\min}^k}{z_{\max}^k - z_{\min}^k} \quad (10)$$

$$\left(z_i^k\right)_n = 2 * \left(\frac{z_i^k - z_{\min}^k}{z_{\max}^k - z_{\min}^k}\right) - 1 \quad (11)$$

Onde:

k = um atributo de maximização ideal 1;

i = uma alternativa de valor z_i^k ;

z_{\min}^k = valor mínimo do conjunto; e

z_{\max}^k = valor máximo do conjunto.

Quanto à arquitetura, as redes foram do tipo não recorrentes alimentadas adiante com múltiplas camadas (ver Figura 7, p. 78), adotando as perceptron multicamadas – PMC.

¹² *Net*: sinal total que entra no corpo de processamento do neurônio artificial. Seu valor é calculado através da multiplicação do sinal que chega ao neurônio pelo peso da sinapse em questão.

¹³ *Logsig*: função de transferência logarítmica sigmoidal do MATLAB. Calcula o valor da saída do neurônio a partir das entradas do *net*, ou seja, o valor que será transferido para a próxima camada, utilizando uma função logarítmica sigmoidal que varia entre 0 e +1. Possui formato de “S”, sendo uma função não linear.

¹⁴ *Tansig*: função de transferência tangente hiperbólica sigmoidal do MATLAB. Apresenta a mesma definição da função anterior. Entretanto, utiliza como função de transferência a tangente hiperbólica sigmoidal, que varia entre -1 e +1.

Segundo Silva (2005), as soluções heurísticas para a determinação do tamanho de uma RNA PMC devem sempre exprimir o compromisso entre o poder de convergência e a generalização da rede. O autor destaca que a generalização é afetada pelo tamanho e pela adequabilidade do conjunto de treinamento, pela arquitetura da rede e pela complexidade do problema. Partindo-se desse princípio, arquiteturas da rede também foram testadas através de experimentos com diferentes números de camadas ocultas e número de neurônios nessas camadas. A quantidade de camadas avaliadas limitou-se às três camadas. Os testes da quantidade de neurônios nas camadas intermediárias deram-se utilizando as heurísticas apresentadas nas Equações 6, 7 e 8. A abordagem dos testes seguiu recomendações do mesmo autor:

- fixar a arquitetura e o tamanho da rede e variar o conjunto de treinamento; ou
- fixar o conjunto de treinamentos e variar a arquitetura da RNA.

O processo de aprendizado das redes neurais foi o aprendizado supervisionado, em que os conjuntos de entradas e saídas das redes eram conhecidos. O algoritmo de aprendizagem adotado foi o algoritmo da retropropagação do erro.

A regra originalmente utilizada para esse algoritmo foi a regra Delta, que consiste na aplicação do Gradiente Descendente, apresentado no item 2.3.6.1, p.84. Devido a sua aplicação amplamente difundida, o Gradiente Descendente foi o primeiro algoritmo de otimização adotado neste trabalho.

Outro algoritmo bastante difundido e abordado neste trabalho foi o Levenberg-Marquardt, descrito no item 2.3.6.2, p. 85. Por fim, uma das formas de melhorar a generalização da rede e evitar o superajuste foi a utilização de métodos de regularização. Sendo assim, o algoritmo de Regularização Bayesiana, descrito no item 2.3.6.3, p. 86 também foi abordado.

Como terceiro passo, os parâmetros de treinamento foram aplicados para controlar o treinamento. A definição destes controles, tais como: taxa de aprendizado ¹⁵, momentum e gradiente mínimo ¹⁶ (referentes ao aprendizado da rede); regras para definir a quantidade de

¹⁵ Taxa de aprendizado: geralmente varia entre 0.1 e 1. Quanto mais baixo for o seu valor, mais lento será o aprendizado.

¹⁶ Gradiente mínimo de descida: determina um vetor de pesos que minimiza o erro; o parâmetro gradiente mínimo estabelece o desempenho mínimo desse gradiente.

ciclos para cada verificação de validação; e critérios de parada de treinamento foram definidos baseando-se em valores indicados na bibliografia e experimentação adequados a cada teste abordado no método específico de cada capítulo.

Existem vários tipos de critérios de parada do treinamento das redes neurais. O programa EasyNN-plus oferece 11, o MATLAB permite a programação do critério. Os critérios baseiam-se fundamentalmente em (i) se o erro estiver diminuindo (conjunto treino ou validação); (ii) se o erro estiver aumentando; (iii) quando todas as previsões forem acertadas ou um erro final desejado atingido; (iv) quando um percentual do conjunto de validação atingir determinado erro mínimo; (v) por tempo de treinamento; e (vi) por número máximo de épocas¹⁷.

A análise de desempenho das redes foi feita com base na análise individual e na média dos erros dos múltiplos treinamentos das redes neurais. Dessa forma, foi possível mapear tendências do comportamento das tipologias de redes estudadas.

A análise de desempenho contemplou o erro observado para um determinado período (e_t) (ver Equação 12), o erro absoluto (EA) (ver Equação 13), o erro absoluto médio (EAM) (ver Equação 14), o erro percentual (EP_t) (ver Equação 15), o erro percentual absoluto (EPA) (ver Equação 16), o erro percentual absoluto médio (EPAM) (ver Equação 17), o erro quadrático médio (EQM) (ver Equação 18) e o erro quadrático médio normalizado (EQMN) (ver Equação 19) (ALMADA-LOBO, 2007). A apresentação desses erros deu-se conforme a adequabilidade da análise. Em alguns casos observou-se também o desvio padrão dos erros (σ) e o coeficiente de determinação (R^2) dos conjuntos treinados pelas RNA.

$$e_t = Z_t - \hat{Z}_t \quad (12)$$

Onde:

e_t : erro no período t ;

Z_t representa o valor observado no período t ; e

\hat{Z}_t : corresponde ao valor estimado pelo modelo no período t .

¹⁷ Épocas: número de interações para o treinamento.

$$EA = |e_t| \quad (13)$$

Onde:

EA: erro absoluto; e

e_t : erro no período.

$$EAM = \frac{\sum_{t=1}^n |e_t|}{n} \quad (14)$$

Onde:

EAM: erro absoluto médio;

e_t : erro no período; e

n: é igual ao número de registros (períodos) usados.

$$EP_t = \left(\frac{Z_t - \hat{Z}_t}{Z_t} \right) \times 100 \quad (15)$$

Onde:

EP_t : erro percentual no período t;

Z_t representa o valor observado no período t; e

\hat{Z}_t : corresponde ao valor estimado pelo modelo no período t.

$$EPA = |EP_t| \quad (16)$$

Onde:

EPA: erro percentual; e

EP_t : erro percentual no período t.

$$EPAM = \frac{\sum_{t=1}^n |EP_t|}{n} \quad (17)$$

Onde:

EPAM: erro percentual absoluto médio;
 EP_t: erro percentual no período t; e
 n: é igual ao número de registros (períodos) usados.

$$EQM = \frac{\sum_{t=1}^n e_t^2}{n} \quad (18)$$

Onde:

EQM: erro quadrático médio;
 e_t: erro no período; e
 n: é igual ao número de registros (períodos) usados.

$$EQMN = \frac{EQM}{(y_{\max} - y_{\min})} \quad (19)$$

Onde:

EQMN: erro quadrático médio normalizado;
 EQM: erro quadrático médio;
 y_{max}: maior valor observado da variável a ser predita; e
 y_{min}: menor valor observado da variável a ser predita.

Esses erros foram avaliados para o conjunto de treinamento, validação e teste individualmente e para o conjunto total de dados. Essa consideração foi feita, pois a maioria dos trabalhos consultados na revisão de literatura apresenta apenas os erros das redes neurais para o conjunto total de dados. Como o conjunto de testes geralmente é menor que o do treinamento, a média geral do erro da rede tende ao erro do treinamento, que, na maioria dos casos, é significativamente menor que o do conjunto de testes, mascarando as limitações dos metamodelos. Além da análise de erros para todos os conjuntos das RNAs, analisou-se cada parâmetro de saída das redes individualmente e todos juntos, visando uma visão global do desempenho das mesmas.

A análise sistemática gera muitos gráficos para permitir o processo descrito no item 3.1, p. 101, em que cada ação deve ter seus resultados analisados para a definição do próximo passo. Entretanto, a avaliação de diversos tipos de erros em conjunto permitiu a observação dos resultados em termos percentuais, absolutos e de resíduos. Essa avaliação se fez necessária porque os parâmetros de saída das RNAs muitas vezes apresentaram magnitudes significativamente diferentes, não permitindo comparações em termos absolutos. O erro percentual, isoladamente, também pode levar a ruídos, no caso de valores absolutos muito baixos. Em alguns casos os erros foram avaliados sobre os valores normalizados, mas, na maioria, optou-se por observar os valores absolutos em suas unidades reais. Seria inviável apresentar todos os gráficos neste texto, visto que o Capítulo 5 isoladamente gerou mais de 400 gráficos para a análise dos resultados. Assim, priorizou-se apresentar os gráficos de EPAM, sendo, por vezes, complementados com informações ou gráficos dos outros tipos de erros.

A literatura consultada recomenda separar um percentual do conjunto de dados para ser apresentado à rede após o seu treinamento, de forma a testar o seu poder de generalização. Entretanto, acredita-se que, no caso de metamodelos, em que as RNAs baseiam-se em modelos paramétricos simulados computacionalmente, esse método não é completamente eficaz. Entende-se que essa proposição vem de estudos com RNAs baseadas em dados reais, como experimentos biológicos com coletas de amostras, por exemplo. No caso de metamodelos baseados em simulações paramétricas, ao separar-se um percentual do conjunto para teste, a rede neural, de certa forma, já “viu” essas variáveis (parâmetros) durante o processo de aprendizado. Ela não viu determinada combinação entre as variáveis que estão no conjunto de testes, mas sim os valores adotados para essas. Visando a um método de teste mais exigente, foram propostos modelos com características não apresentadas à rede durante o treinamento, denominado aqui de conjunto de casos “nunca vistos”.

Testar a rede com modelos “nunca vistos” é de fundamental importância para se definirem as limitações dos metamodelos, especialmente para métodos simplificados que intencionem aplicar redes neurais artificiais baseadas em metamodelagem paramétrica. Como a quantidade de casos a serem simulados para treinar as redes é limitada pela viabilidade de tempo, logo as soluções arquitetônicas e de contexto do edifício apresentadas às redes serão também limitadas. Assim, a rede tem que ser capaz de generalizar não somente novas combinações das variáveis que lhe foram apresentadas (abordagem da literatura), como

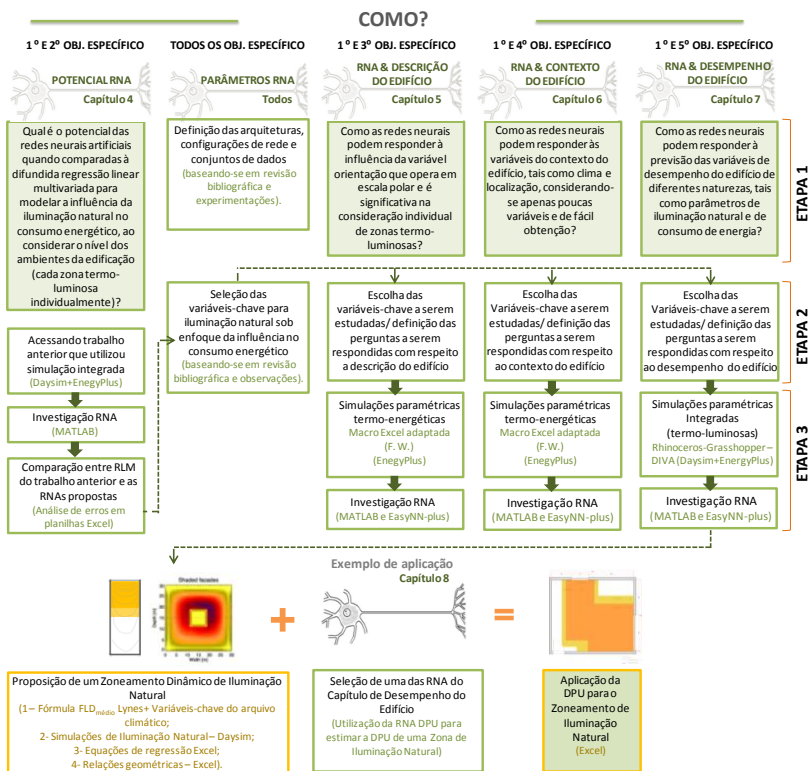
também novos valores para essas variáveis que, mesmo dentro dos limites dos valores apresentados no treinamento, ainda não foram apresentados à rede. Sendo assim, a combinação dos dois métodos de teste pode ser mais efetiva, permitindo por meio do primeiro verificar o potencial da rede para generalização e por meio do segundo delimitar os seus limites.

3.5 CONSIDERAÇÕES FINAIS SOBRE O CAPÍTULO

O método proposto visou responder às perguntas de pesquisa e, conseqüentemente, aos objetivos específicos deste trabalho. A Figura 16 mostra o resumo das ações metodológicas abordadas nos próximos capítulos, bem como as ferramentas utilizadas, associadas às perguntas de pesquisa e aos objetivos específicos. A figura trata-se de um desdobramento da pergunta “Como?” apresentada no mapa conceitual da tese (ver Figura 2, p.48) e relaciona as etapas metodológicas destacadas na Figura 12, p. 103.

A determinação do tipo de variáveis-chave a serem utilizadas foi de extrema importância para nortear a investigação dos parâmetros que influenciam a iluminação natural e o seu impacto no desempenho energético dos modelos. Além disso, permitiu a divisão do estudo em três núcleos principais: descrição do edifício, contexto do edifício e desempenho do edifício.

Figura 16 – Resumo das ações metodológicas abordadas nos próximos capítulos relacionadas às perguntas de pesquisa e aos objetivos específicos



Fonte: Autor.

4. POTENCIAL DAS RNAs PARA A MODELAGEM DO CONSUMO ENERGÉTICO CONSIDERANDO A ILUMINAÇÃO NATURAL

Com a intenção de avançar na modelagem energética considerando a iluminação natural, buscou-se comparar o desempenho das Redes Neurais Artificiais (RNA) com a difundida Regressão Linear Multivariada (RLM). Assim, foi feita uma comparação entre o modelo proposto por Didoné (2009) para a predição de um índice de Consumo de Iluminação Natural baseado em RLM e uma proposta de RNA.

4.1 INTRODUÇÃO

Regressão Linear Multivariada é uma técnica comumente utilizada para análise de dados em diversas áreas de pesquisa, como, por exemplo, análise paramétrica de parâmetros construtivos, análise de envelope para diferentes tamanhos de janelas, tipos de vidro e elementos de sombreamento ou níveis de eficiência energética na indústria da construção civil (CARLO, 2008; CHUNG; HUI; LAM, 2006; GIBSON, 2011; INMETRO, 2010; MORET; NORO; PAPAMICHAEL, 2013; SIGNOR, 1999; WESTPHAL; LAMBERTS, 2007).

A comparação entre RNA e RLM para modelar o comportamento termoenergético de edificações já foi abordada por Melo (2012), que avaliou a consistência da RLM proposta por Carlo (2008) para determinar um Indicador de Consumo Energético adimensional diante de uma solução de RNA. A autora identificou limitações da RLM, como, por exemplo, com relação à modelagem da volumetria do edifício, da transmitância térmica das paredes ou dos vidros de alto desempenho. Melo (2012) propôs um metamodelo baseado em RNA MPL com Gradiente Descendente baseado na retropropagação do erro. O treinamento das redes baseou-se em casos simulados no programa de modelagem termoenergética EnergyPlus. A autora obteve resultados mais precisos que o método anterior, com resultados diretamente em unidade de consumo energético (kWh/m²/ano).

Entretanto, esses trabalhos não consideraram o aproveitamento de iluminação natural. Nesse sentido, Didoné (2009) propôs equações de RLM para prever o consumo energético, considerando a iluminação natural para Florianópolis no contexto do RTQ-C (INMETRO, 2010), conforme explicado na nota de rodapé 3, p. 54. O trabalho foi importante para reforçar a necessidade de se considerar a iluminação natural no desempenho energético da edificação. Algumas limitações

inerentes ao trabalho são a limitação das variáveis-chave de iluminação natural escolhidas (o vidro é representado apenas pelo fator solar, não considerando a transmissão visível, por exemplo), as geometrias adotadas para as simulações e a desconsideração da orientação por parte das equações. Este último item mostrou uma limitação da abordagem linear do método, visto que o programa gerador da equação indicou esse parâmetro como não importante, ao passo que é consenso a importância da orientação para a iluminação natural, em especial quando se consideram aberturas em uma só fachada.

Assim, neste capítulo o foco foi avaliar o desempenho da técnica de RNA aplicada ao conjunto de dados de Didoné (2009).

4.2 DETALHAMENTO DO MÉTODO

A principal pergunta de pesquisa que direcionou a proposição deste capítulo foi:

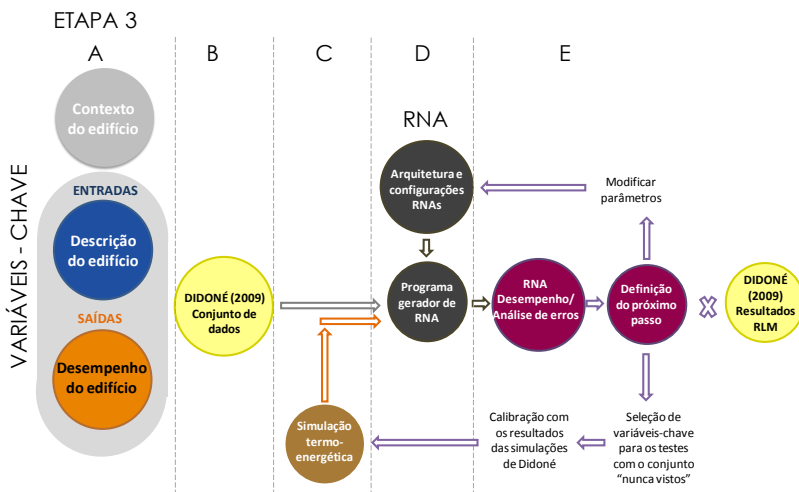
Qual é o potencial das redes neurais artificiais quando comparadas à difundida regressão linear multivariada para modelar a influência da iluminação natural no consumo energético, ao considerar o nível dos ambientes da edificação (cada zona termoluminosa individualmente)?

Essa pergunta desdobrou-se em três perguntas de pesquisa, que nortearam o desenvolvimento da investigação abordada neste capítulo, quais sejam:

- As RNAs conseguem modelar todas as variáveis-chave propostas por Didoné (2009), incluindo a orientação?
- Qual a influência da função de transferência para modelar as variáveis-chave adotadas?
- O quão efetivas as RNAs podem ser para generalizar resultados para casos com características arquitetônicas que não tivessem feito parte do conjunto dos modelos paramétricos?

A Figura 17 ilustra as ações metodológicas realizadas neste capítulo, conforme a etapa metodológica 3, ilustrada na Figura 12, p. 103, do capítulo do método geral.

Figura 17 – Aplicação da etapa metodológica 3: avaliação do potencial das RNAs frente à RLM




Fonte: Autor.

4.2.1 Descrição da base de dados de Didoné (2009)

Os detalhes da pesquisa de Didoné (2009) pertinentes a este trabalho serão apresentados neste item, tendo sido aqui alocados por fazerem parte do procedimento metodológico. A escolha das variáveis-chave e respectivos valores adotados, o método para a RLM, bem como seus resultados apresentados nos itens 4.2.1.1 e 4.2.1.2, respectivamente, foram extraídos do trabalho de Didoné (2009). Essas informações constam no presente trabalho apenas para permitir a comparação com o método de RNA, tendo sido mantidas inalteradas independentemente da crítica a sua adequabilidade.

O conjunto de dados utilizados possuía 216 modelos de salas de escritórios, divididos em três geometrias diferentes nas quais apenas a profundidade dos ambientes apresentava diferentes tamanhos (ver Figura 18).

Figura 18 – Esquema da geometria dos modelos de Didoné (2009)



Fonte: adaptado de: Didoné (2009).

O consumo de energia dessas tipologias foi obtido através da simulação computacional, com a integração entre dois programas: o Daysim/RADIANCE e o EnergyPlus (método de integração descrito no Apêndice B2, p.420, deste trabalho; entretanto, sem a utilização da interface DIVA).

Para os dados de entrada no programa de simulação, foram utilizados as características construtivas, de uso e ocupação dos modelos, segundo a Tabela 2, e o relatório de controle de iluminação artificial, obtido na simulação de iluminação.

Tabela 2 – Características construtivas, de uso, ocupação e iluminação

Transmitância Térmica [W/(m ² .K)]	Paredes	2,47
	Cobertura	2,42
Capacidade Térmica [KJ/(m ² .K)]	Paredes	200
	Cobertura	187
Absortância (%)	Paredes	0,65
	Cobertura	0,70
Ocupação média (m²/pessoa)	Não foi abordado por Didoné (2009)	-
Densidade de carga interna (W/m ²)	Iluminação	7
	Equipamentos	9,7
Padrão de uso (horas)	Ocupação	8-18 *
	Iluminação	8-18 *
	Equipamentos	8-18 *
Características do sistema de condicionamento de ar	Tipo	Aparelho de janela
	Capacidade de refrigeração (BTU/h)	Ideal para o protótipo
	COP ($W_{\text{térmico}}/W_{\text{elétrico}}$)	3,15

Fonte: Didoné (2009).

Nota: * 100% da ocupação, do uso da iluminação e dos equipamentos durante o período mencionado e nulo fora desse período.

As refletâncias internas utilizadas foram as seguintes: 70% para o teto, 50% para as paredes e 20% para o piso. Para o sistema de iluminação artificial, foi definido um projeto eficiente com luminárias de embutir de alta eficiência e aletas metálicas. Foram utilizadas lâmpadas fluorescentes tubulares T5 de 28 W. A iluminância de projeto seguiu as recomendações da NBR 5413 (ABNT, 1992), com valor de 500 lux. Como resultado final da análise, tem-se o consumo energético do modelo em kWh/m²/ano.

As variáveis-chave utilizadas foram a orientação (N, S, L e O), o Percentual de Área de Abertura da Fachada (PAF: 25%, 50% e 75%), o Fator Solar do vidro (FS: 0,23 e 0,82), os Ângulos Verticais e Horizontais de Sombreamento (AVS: 0° e 45°, AHS: 0° e 45°) e a Profundidade do Ambiente (PROF). Para esta última, foi utilizada uma razão do valor da profundidade do ambiente por 20 (PROF/20), já as equações desenvolvidas limitaram-se a avaliar ambientes com profundidade de até 20 m.

4.2.1.1 *A Regressão Linear Multivariada de Didoné (2009)*

Didoné (2009) elaborou o modelo de regressão utilizando o programa SPSS 16.0.¹⁸ Os dados de consumo, obtidos através de simulação computacional, foram processados pelo programa, que gerou uma equação que relaciona as variáveis em estudo. O programa forneceu as estatísticas de uma reta usando o método dos mínimos quadrados para obter uma equação linear que ajustasse os dados, retornando uma matriz que descrevesse essa reta. O modelo é descrito pela relação demonstrada na Equação 20.

$$y = \beta_0 + \beta_1 * x_1 + \beta_2 * x_2 + \dots + \beta_n * x_n \quad (20)$$

Os valores de β são coeficientes que correspondem a cada valor de x . A tendência linear de y das seis variáveis x inseridas pode ser descrita como o y correspondendo ao consumo de energia elétrica; o x , às variáveis consideradas relevantes para o aproveitamento da luz natural no desempenho energético de edificações; e o n , ao número de variáveis x utilizadas na equação.

As análises de desempenho das equações foram feitas por meio do coeficiente de determinação ou de explicação (R^2), do desvio padrão para a estimativa de y e do teste t (*t Student*), que serviu para testar a igualdade das médias do consumo obtido pela simulação com as médias dos consumos obtidos das equações.

Para atingir o objetivo proposto, os mesmos dados de entrada para a análise pela RLM foram utilizados como dados de entrada para a análise utilizando as RNAs, tornando possível a comparação entre os dois modelos de análise de regressão para representar o potencial de economia de energia com o uso da iluminação natural.

4.2.1.2 *Proposta de Equação Linear Multivariada por Didoné (2009)*

Durante o processo de proposição da equação, a variável Orientação foi excluída pelo programa SPSS 16.0 por não contribuir significativamente para o modelo.

Neste estudo inicial a correlação dos dados do consumo Equacionado (referente aos valores obtidos com o uso da Equação 20 e dos dados do consumo Simulado (referente aos valores obtidos com a

¹⁸ SPSS 16.0 é um programa computacional com um sistema para análise de dados que permite aplicação analítica, *data mining*, *text mining* e análise estatística.

simulação computacional integrada) resultou na Equação 21 com um coeficiente de correlação (R) de 0,70 e um coeficiente de determinação (R^2) de 0,4922.

$$IC_{LuzNat} = 82,39 + 15,282 * PAF - 11,18 * AVS - 8,799 * AHS + 5,303 * FS - 6,1 * PROF \quad (21)$$

Onde:

IC_{LuzNat} = indicador de consumo com o uso da luz natural [kWh/m²/ano];

PAF = porcentagem de abertura da fachada [%];

AVS = ângulo vertical de sombreamento [grau];

AHS = ângulo horizontal de sombreamento [grau];

FS = fator solar [%]; e

PROF = profundidade [razão (PROF/20)].

Após avaliar a influência das variáveis utilizadas individualmente na Equação 21, a autora optou por associá-las com o intuito de elaborar uma equação que apresentasse um resultado mais satisfatório, a Equação (22)

(22). As associações foram realizadas através de divisões e/ou multiplicações entre as variáveis de acordo com as suas relações e desempenho apresentado. As associações que apresentaram o resultado mais satisfatório foram PAF/PROF, FS x PAF, PAF x AVS x FS/PROF, PAF x AHS x FS/PROF, PAF x AVS x FS e PAF x AHS x FS. Como resultado, obtiveram-se um coeficiente de correlação linear (R) de 0,79 e um coeficiente de determinação (R^2) de 0,6243.

$$\begin{aligned} IC_{LuzNat} = & 79,033 + 3,347 * PAF / PROF + 23,109 * FS * PAF \\ & - 7,433 * PAF * AVS * FS / PROF - 5,34 * PAF * AHS * FS / PROF \\ & - 20,903 * PAF * AVS * FS - 18,2 * PAF * AHS * FS \end{aligned} \quad (22)$$

Para melhorar a precisão do modelo, a autora reduziu o conjunto de dados ao considerar 95% dos valores em torno da reta de regressão. Esse intervalo de confiança¹⁹ foi considerado satisfatório por Didoné


¹⁹ Intervalos de confiança são construídos para indicar que, em x% das vezes que essa experiência for repetida, aquele valor seja detectado no estudo. São valores arbitrados segundo a ótica do pesquisador para atribuir alto grau de confiabilidade ao trabalho. Os valores usuais partem de 80%, 90%, 95%, 97,5%, 99%, 99,5% ou 99,9%. É de bom senso utilizar um valor intermediário que permita analisar o grau de confiabilidade coerente com a realidade (MONTGOMERY; RUNGER, 2003).

(2009), resultando em um coeficiente de correlação (R) de 0,89 e de determinação (R^2) de 0,8028 (ver Figura 19). A Equação final resultante foi obtida a partir de 205 casos simulados que se encontravam no nível de confiança determinado pela reta de regressão (ver Equação 23).

$$\begin{aligned}
 IC_{LuzNat} = & 78,09 + 4,187 * PAF / PROF + 27,779 * FS * PAF \\
 & - 9,51 * PAF * AVS * FS / PROF - 4,384 * PAF * AHS * FS / PROF \\
 & - 26,188 * PAF * AVS * FS - 28,795 * PAF * AHS * FS
 \end{aligned} \tag{23}$$

Os dados da equação final resultaram em um desvio padrão de 2,90; e o teste t mostrou que as médias das amostras simuladas e equacionadas são consideradas iguais. Utilizando-se as variâncias referentes a cada coeficiente adotado na equação, o t calculado foi de 90,85.

Figura 19 – Consumo anual de energia Simulado x Equacionado por RLM



Fonte: Didoné (2009).

4.2.2 Aplicação de Redes Neurais Artificiais

Para a comparação com as RNAs, propôs-se uma rede baseada no conjunto de dados fornecido em planilha Excel pela autora do estudo original. A rede foi treinada e testada por meio do programa MATLAB, conforme procedimento descrito no item 3.4.3 do método geral.

Como primeiro passo, a definição dos padrões, adotaram-se as mesmas variáveis de entrada da simulação integrada de Didoné (2009) (orientação, PAF, FS, AVS e AHS e Profundidade), bem como as de saída (consumo energético total). Os dados fornecidos pela autora foram

formatados de maneira que pudessem ser utilizados para o treinamento da RNA. Portanto, foram tratados de duas maneiras: os que correspondiam às variáveis qualitativas foram tratados de forma binária, sendo indicado o número 1 quando a variável estava presente e 0 quando não estava presente; já os parâmetros representados por variáveis quantitativas contínuas foram normalizados.

No caso deste estudo, as variáveis quantitativas contínuas são profundidade, orientação, fator solar e PAF, enquanto as qualitativas são AVS e AHS. Os ângulos de sombreamento foram classificados como variáveis qualitativas, por terem sido considerados de forma simplificada, computando apenas se estavam presentes ou não em determinada tipologia.

A normalização dos dados foi feita a fim de permitir testar o desempenho da rede com duas funções de transferência: logarítmica sigmoideal (dados entre 0 e 1), segundo Equação 10, p.116; e tangente hiperbólica sigmoideal (dados entre -1 e +1), segundo Equação 11, p.116.

Para o treinamento e a validação da RNA, foi utilizado o método da validação cruzada *multi-fold*, conforme descrito no item 3.4.3, p. 115, do capítulo do método geral. Para a aplicação da validação cruzada, o conjunto de dados referentes aos modelos simulados por Didoné (2009) foi dividido em 10 subconjuntos K, sendo o conjunto de validação considerado 1/K. Assim, o conjunto com 216 casos foi subdividido em subconjunto de treinamento, com 195 casos, e subconjunto de teste, com 21 casos, ambos selecionados randomicamente.

Como segundo passo, determinou-se o tipo de rede para proceder a sua inicialização; no caso deste capítulo, foi adotada uma PMC alimentada adiante com Gradiente Descendente baseado na retropropagação do erro aplicado com taxa de aprendizado adaptativo (*traingda*²⁰). A rede foi testada com as funções de transferência (ou função de ativação) *logsig* e *tansig*. O teste foi feito de forma completa para as 10 rodadas da validação cruzada. Definiu-se o número de neurônios na camada intermediária (ver item 2.3.5, p. 81) por meio de testes.

Como parâmetros de treinamento, foram definidos o gradiente mínimo como 0,0001; o erro final desejado como 0,000001; e a taxa de aprendizado como 0,001. Para a adoção do número de épocas no

²⁰ Traingda: função de treinamento gradiente descendente com taxa de aprendizado adaptativo baseado na retropropagação do erro do MATLAB. Essa função de treinamento atualiza os valores dos pesos e dos bias de acordo com o Gradiente descendente com taxa de aprendizado adaptativo.

treinamento, iniciou-se com 10.000 épocas, passando a 20.000, 50.000 e, por fim, 100.000 épocas.

Escolheu-se para a comparação entre as técnicas estatísticas a tipologia de rede que apresentou maior coeficiente de correlação e menor EQM, ou seja, a que forneceu estimativas mais próximas aos valores observados (valores de consumo obtidos por Didoné (2009) através da simulação integrada).

4.2.3 Potencial de generalização para novos casos

O potencial de generalização das redes foi avaliado segundo o conjunto de casos “nunca vistos”, como explanado no item 3.4.3 do método geral. As variáveis selecionadas foram orientação, AVS e geometria, escolhidas por terem sido abordadas superficialmente no conjunto de dados de Didoné (2009). A primeira linha da Tabela 3, referente a “Valores-base”, mostra os dados dos modelos adotados como referência para sofrer as alterações propostas. Os modelos-base foram propostos conforme o conjunto de Didoné (2009) e, diante da impossibilidade de acesso aos modelos originais, foram refeitos seguindo-se as informações disponíveis no capítulo do método do trabalho da autora. Os valores alterados são exibidos nas linhas referentes a “Parâmetros Variados um por Vez”.

Tabela 3 – Variáveis da descrição do edifício adotadas para o teste da rede utilizando o conjunto “nunca vistos”

	Profundidade/Geometria	Orientação	FS	PAF	AVS	AHS
Valores-base	4 m profundidade x 8 m largura	N, S, L e O	0,82	25%	45°	0°
Parâmetros Variados um por Vez	4 m largura x 8 m profundidade	359° (N)			30°	
	16 m de largura e 8 m profundidade	NE			60°	
		NO				
		SE				
		SO				

Fonte: Autor.

Os modelos propostos foram simulados nos mesmos programas e com as mesmas características adotadas pelo estudo anterior, sendo calibrados para corresponder o mais fielmente possível ao conjunto de origem. O erro entre a simulação integrada refeita do modelo-base e o resultado de Didoné (2009) foi utilizado para ajustar os erros do conjunto “nunca vistos”.

Entre as 10 RNAs treinadas através do método da validação cruzada utilizando a função logarítmica sigmoideal, três RNAs foram escolhidas para testar o conjunto “nunca vistos”, as duas que apresentaram o melhor desempenho e a que apresentou o pior desempenho. A análise de erros foi feita depois de os valores estimados pela rede serem desnormalizados (voltando à sua escala real em kWh/m².ano).

4.3 RESULTADOS

Os resultados são apresentados da seguinte forma: primeiramente, discutem-se os resultados obtidos através da proposição de RNA; em seguida, comparam-se os resultados com os obtidos através da RLM por Didoné (2009); e, por fim, investiga-se o potencial de generalização da rede neural.

4.3.1 Redes Neurais Artificiais para o conjunto de Didoné (2009)

A arquitetura da rede ficou estruturada com seis parâmetros de entrada, 10 neurônios na camada oculta e um parâmetro de saída. O número de parâmetros de entrada e o de saída não variaram, visto que

correspondem, respectivamente, às seis variáveis-chave e ao consumo energético dos casos simulados. A quantidade de neurônios para a camada oculta se mostrou adequada por levar a erros menores que as outras quantidades testadas. A quantidade de neurônios ocultos aproximou-se da recomendada pela heurística da Equação 8, apresentada na revisão bibliográfica no item 2.3.5, p. 83, uma vez e meia a quantidade de padrões de entrada.

O algoritmo de treinamento adotado, Gradiente Descendente com taxa de aprendizado adaptativo (*traingda*), mostrou-se adequado, visto que ambas as tipologias de rede (*logsig* e *tansig*) apresentaram erros abaixo de 0,05, como recomenda a bibliografia especializada.

Apesar de demandar um pouco mais de tempo de treinamento, julgou-se 100.000 um número adequado de épocas de treinamento para esse problema. Na maior parte dos casos o melhor desempenho ficou na casa das 99.900 épocas.

A Tabela 4 apresenta os resultados dos coeficientes R^2 e R (média das 10 rodadas da validação cruzada considerando todo o conjunto de dados) e dos erros EQM e EAM (média das 10 rodadas da validação cruzada considerando o conjunto de teste) utilizando ambas as funções. Como se pode notar, os coeficientes R^2 e R obtidos através das duas funções são muito próximos; se arredondados para duas casas decimais, ficariam iguais. Já os valores de EQM e EAM do grupo da função *logsig* apresentaram resultados mais baixos. Esse foi o argumento de decisão para a escolha da função *logsig* quando comparada com a RLM. Pode-se perceber que, em todos os casos de treinamento, o R^2 aproximou-se de 0,99, o que representa uma forte correlação dos dados. O EQM dos conjuntos de testes variou entre 0,02 e 0,05 e a média ficou em 0,0303, inferior a 0,05, como recomenda a bibliografia especializada. Já o EAM não ultrapassou 0,05 em nenhum dos casos. O desvio padrão de todo o conjunto foi considerado baixo e igual a 0,1565 kWh/m² ano.

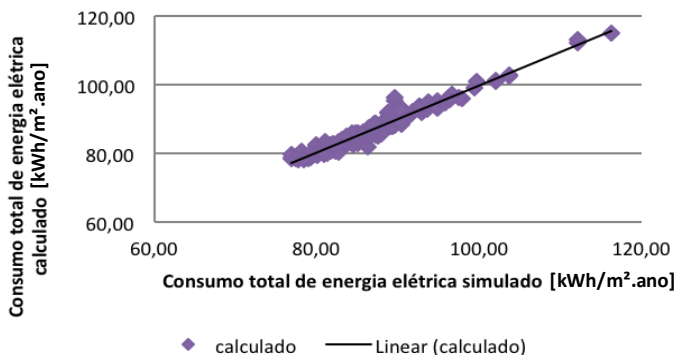
Tabela 4 – Comparativo entre os resultados obtidos através das duas arquiteturas de redes, com função de transferência *logsig* e *tansig* (erros normalizados)

Rodada	Grupo Função <i>Logsig</i>				Grupo Função <i>Tansig</i>			
	R ²	R	EQM	EAM	R ²	R	EQM	EAM
Média	0,9867	0,9933	0,0303	0,0221	0,9900	0,9950	0,0551	0,0389

Observando a Figura 20, pode-se notar que a dispersão dos pontos em relação à reta diminuiu consideravelmente em relação à

Figura 19, p. 132, em que foram plotados os resultados da equação gerada por RLM.

Figura 20 – Consumo anual de energia Simulado x Calculado pela RNA através da função *logsig*



4.3.2 Comparações entre os modelos de regressão

A comparação entre os coeficientes R^2 obtidos através das duas formas de regressão indica que o modelo não linear (RNA) representa melhor a função que descreve o consumo energético considerando a iluminação natural. O R^2 médio obtido pela RNA, tanto para a função *logsig* quanto para a *tansig*, foi superior a 0,98, ao passo que, na melhor opção da RLM, foi de 0,80. Vale destacar que, para esta opção da RLM, foi considerado apenas 95% dos casos. Quando todos os dados foram considerados, a RLM obteve R^2 de apenas 0,62. Já o desvio padrão para a RLM foi de 2,90, enquanto que o da RNA foi de 0,16, demonstrando menor dispersão dos dados. O desempenho superior da RNA é reforçado por considerar o parâmetro orientação no modelo, desconsiderado pela RLM.

4.3.3 Potencial de generalização para novos casos

Assumindo que as RNAs foram treinadas a partir do conjunto de dados de Didoné (2009), a simulação integrada dos modelos do conjunto “nunca vistos” foi realizada buscando reproduzir os modelos do treinamento. O erro máximo entre os modelos usados para calibração foi de 2%, como pode ser visto na Tabela 5.

Tabela 5 – Resultados da calibração entre os modelos simulados por Didoné (2009) e os simulados para este trabalho

DADOS DAS SIMULAÇÕES INTEGRADAS (EnergyPlus +Daysim)													
VALIDAÇÃO DAS SIMULAÇÕES COM BASE NOS MODELOS DE DIDONÉ (2009)	CASOS	Profundidade (m)	Orientação (°)	FS	PAF	AVS (°)	AHS (°)	Consumo Energético Total – simulação integrada (kWh/m².ano) – simulações atuais	Consumo Energético Total – simulação integrada (kWh/m².ano) – simulações de Didoné (2009)	EPAM (%) – calculado entre as simulações integradas atuais e de Didoné (2009).			
	N	4	0	0,82	0,25	45	0	83,63	81,96	2,03	↑		
	S	4	180	0,82	0,25	45	0	78,13	77,74	0,50	↑		
	L	4	90	0,82	0,25	45	0	85,34	84,49	1,01	↑		
	O	4	270	0,82	0,25	45	0	85,75	84,76	1,17	↑		
Conjunto “nunca vistos” baseados nos modelos atuais									EPAM (%) para as orientações adjacentes às simuladas		Erro adotado abordagem conservadora		
NOVOS MODELOS	N	L	O	S									
	359 ⁰	4	359	0,82	0,25	45	0	78,58	2,03			2,5%	
	NE	4	45	0,82	0,25	45	0	85,61	2,03	1,01		2,5%	
	NO	4	315	0,82	0,25	45	0	79,07	2,03			1,17	2,5%
	SE	4	135	0,82	0,25	45	0	82,11		1,01		0,50	1,5%
	SO	4	225	0,82	0,25	45	0	82,11			1,17	0,50	1,5%

Analisando-se os resultados das simulações do conjunto “nunca vistos”, assumiu-se um erro percentual de 2,5% passível de ser transferido para a predição da RNA. Considerando-se que as simulações dos casos-base de Didoné (2009) resultaram em consumos menores que as atuais, esperou-se que as RNAs subestimassem os valores obtidos por simulação para esse conjunto.

Para a escolha das redes neurais a serem testadas com o conjunto “nunca vistos”, foram selecionadas as de melhor e as de pior desempenho para a função *logsig*, destacadas na Tabela 6.

Tabela 6 – Resultado do desempenho de cada RNA da validação cruzada do grupo logsig

RNA	Grupo Função <i>Logsig</i>		
	EAM (kWh/m ² .ano)	EQM (kWh/m ² .ano)	EPAM (%)
1	0,7306	1,0787	0,8416
2	0,8523	1,1175	0,9818
3	0,7275	0,8928	0,8381
4	1,2387	1,5970	1,4270
5	0,6702	0,9827	0,7720
6	0,8523	1,1175	0,9818
7	0,7275	0,8928	0,8381
8	1,2387	1,5970	1,4270
9	1,7219	2,5865	1,9836
10	0,7570	0,9661	0,8720



Menores Erros



Maiores Erros

A Tabela 7 apresenta os erros das estimativas de cada uma das três RNAs para cada um com casos “nunca vistos”. Na primeira parte da tabela são apresentadas as variações na orientação; na segunda parte, as variações de AVS; e, na terceira, de geometria. A orientação 359° (N) foi testada para avaliar a necessidade de oferecer mais informações sobre a característica polar da escala em que opera.

Tabela 7– Resultados das estimativas das RNAs para os casos do conjunto “nunca vistos”

DADOS DAS SIMULAÇÕES INTEGRADAS (EnergyPlus +Daysim)								Consumo Energético Total – estimados pelas RNA (kWh/m ² .ano)	ANÁLISE DOS ERROS				
Casos	Profundidade (m)	Orientação (°)	FS	PAF	AVS (°)	AHS (°)	Consumo Energético Total – simulação integrada (kWh/m ² .ano)	RNA 3	valores das RNA em relação aos valores simulados	EAM (kWh/m ² .ano)	EQM (kWh/m ² .ano)	EPAM (%)	EPAM grupo (%)
N359 ⁰	4	359	0,82	0,25	45	0	83,62	86,30	↑			3,20	
NE	4	45	0,82	0,25	45	0	85,15	84,97	↓			0,21	
NW	4	315	0,82	0,25	45	0	86,22	85,89	↓			0,39	
SE	4	135	0,82	0,25	45	0	81,33	77,58	↓			4,61	
SW	4	225	0,82	0,25	45	0	81,70	80,80	↓	1,57	2,11	1,10	1,88
								RNA 5					
								91,62	↑			9,27	
								83,15	↓			2,36	
								89,53	↑			3,85	
								82,34	↑			1,31	
								78,58	↓	3,49	4,24	3,86	4,08
								RNA9					
								101,92	↑			19,96	
								82,22	↓			3,52	
								89,68	↑			3,86	
								81,80	↑			0,57	
								82,05	↑	5,10	8,43	0,44	6,10
AVS – “nunca vistos”								RNA 3					
30	4	0	0,82	0,25	30	0	84,97	87,03	↑			2,43	
60	4	0	0,82	0,25	60	0	82,98	77,97	↓	3,54	3,83	6,04	4,21
								RNA 5					
								85,61	↑			0,74	
								79,07	↓	2,28	2,80	5,02	2,71
								RNA9					
								84,97	↑			0,00	
								82,11	↓	0,00	0,00	0,01	0,00
Geometria – “nunca vistos”								RNA 3					
4x8	8	0	0,82	0,25	45	0	86,39	81,89	↓			5,21	
16x8	8	0	0,82	0,25	45	0	78,16	81,89	↑	4,12	4,13	4,77	5,00
Didoné 8x4	4	0	0,82	0,25	45	0	81,96						
Didoné 8x16	16	0	0,82	0,25	45	0	82,12						
Didoné 8x8	8	0	0,82	0,25	45	0	82,25						
								RNA 5					
								82,11	↓			5,23	
								82,11	↑	4,12	4,12	4,82	5,00
								RNA9					
								81,45	↓			6,01	
								81,45	↑	4,12	4,20	4,01	5,00

A análise dessa tabela permitiu observar que a orientação foi a variável que apresentou maiores erros (RNA 3 e 5), tendo sua investigação aprofundada no próximo capítulo.

Comparando-se os três erros estatísticos, o EQM foi o que apresentou maior convergência entre o erro da RNA de maneira geral (Tabela 6) e o erro dos modelos “nunca vistos” (Tabela 7). Isso porque a RNA 3 apresentou o menor EQM no “treino + teste” e o menor para os conjuntos avaliados individualmente, o que não ocorreu para EAM e EPAM. Essa avaliação foi necessária, pois nem sempre a rede com melhor desempenho no treinamento apresentará melhor desempenho para teste.

Quanto ao teste dos parâmetros de AVS, a RNA 9 apresentou o melhor desempenho, mesmo aplicando-se o erro de 2,03% (Tabela 5, p. 138) decorrente da simulação computacional. Provavelmente, essa rede ajustou-se à influência do AVS em detrimento dos outros parâmetros, o que explicaria o pior desempenho do conjunto treino + teste quando comparado aos mesmos conjuntos das outras RNAs.

As RNAs superestimaram os resultados para $AVS = 30^0$ (com exceção da RNA 9) e subestimaram para $AVS = 60^0$. Essas tendências podem ser explicadas pela existência de apenas um valor de AVS no treinamento e pela adoção de variáveis binárias para a RNA. Como no treino existiam apenas duas opções – sem proteção solar = 0 e com AVS $45^0 = 1 -$, o AVS 30^0 tendeu à solução sem proteção solar e o AVS 60^0 , a algo maior que 45^0 . Os erros maiores para AVS 60^0 justificam-se pela limitação conhecida de redes neurais para a extrapolação.

Quanto à avaliação das diferentes geometrias, devido ao conjunto de Didoné (2009) não variar a largura do ambiente, a RNA não pode aprender a diferenciar os ambientes. Ambos os modelos testados e o modelo de Didoné (2009) com 8 m de largura por 8 m de profundidade (linha azul escuro da Tabela 7) possuem a mesma descrição de parâmetros. Logo, a RNA fez a mesma previsão, tendendo ao resultado desse modelo.

As três RNAs apresentaram desempenho semelhante, tendo a RNA 3 apresentado os menores erros e a RNA 9, os maiores, seguindo a tendência do conjunto de treino + teste. Entretanto, a RNA 5 apresentou o resultado mais próximo do modelo de Didoné (2009) de mesmas entradas (linha azul escuro da Tabela 7). Para as três redes, o modelo 4m x 8m apresentou EPAMs maiores que o modelo 16m x 8m, possivelmente, porque fisicamente esse modelo diferencia-se mais do modelo de mesmas entradas apresentado no treinamento da rede. Devido às suas proporções geométricas (geometria profunda 4m x 8m), é mais

sensível ao gradiente da iluminação que os outros. Os parâmetros de entrada adotados não foram suficientes para “explicar” para a rede neural os efeitos desses fenômenos.

A Tabela 8 salienta as relações geométricas entre os modelos “nunca vistos” e os modelos de características semelhantes, considerando as três profundidades adotadas por Didoné (2009). As principais variáveis e as relações geométricas foram listadas e comparadas. As cores rosa claro e rosa escuro destacam os valores em comum que os diferentes modelos apresentam para as variáveis geométricas adotadas (largura, profundidade, área, PAP, área de abertura, PAF e proporção entre largura e profundidade). O consumo energético foi detalhado conforme uso final, tendo a análise considerado as variáveis geométricas exclusivas dos modelos de maior consumo para cada uso final (destacados em roxo na Tabela 8). Essa análise possibilitou as seguintes observações:

- Consumo Energético Total: as variáveis mais representativas foram largura, abertura e área de fachada. Essas três variáveis foram as únicas que não eram comuns aos outros modelos, tanto para o modelo de maior consumo energético total quanto para o de menor (destacado em lilás na Tabela 8);
- Consumo Iluminação: a variável mais representativa foi a proporção entre largura e profundidade, visto que foi a variável comum entre apenas os dois modelos de maior consumo para iluminação; e
- Consumo Resfriamento: as variáveis mais representativas foram o percentual de área de abertura por área de piso e a profundidade do ambiente, por tratar-se das variáveis com valores exclusivos para o modelo de maior consumo para resfriamento.

Tabela 8 – Comparação das relações geométricas entre os modelos e seus respectivos consumos energéticos destacados por uso final.

CASOS	DADOS GEOMÉTRICOS							CONSUMO ENERGÉTICO TOTAL – SIMULAÇÃO INTEGRADA (kWh/m ² .ano)					
	Largura (m)	Profundidade (m)	Área (m ²)	PAP (%)	Área de Abertura (m ²)	Área de Fachada (m ²)	PAF (%)	Proporção largura x profundidade	Consumo Energético Total	Iluminação Artificial	Ventiladores (A.C.)	Aquecimento (A.C.)	Resfriamento (A.C.)
4x8	4	8	32	0,08	2,7	10,8	0,25	1x2	86,39	21,96	3,04	0,00	25,98
16x8	16	8	128	0,08	10,8	43,2		2x1	78,16	15,84	2,81	0,00	24,10
Didoné 8x4	8	4	32	0,17	5,4	21,6		2x1	81,96	16,44	3,16	0,00	26,94
Didoné 8x16	8	16	128	0,04	5,4	21,6		1x2	82,12	20,30	2,76	0,00	23,65
Didoné 8x8	8	8	64	0,08	5,4	21,6		1x1	82,25	19,22	2,89	0,00	24,73

Nota: as cores utilizadas na tabela são indicativas de valores em comum entre os modelos.

Com base nessas observações, recomenda-se que as RNAs idealizadas para prever o consumo energético (térmico e luminoso), além de utilizar a variável-chave PAF, completem os parâmetros de entrada com variáveis como PAP e proporção do ambiente.

4.4 CONSIDERAÇÕES FINAIS SOBRE O CAPÍTULO

Neste capítulo foram comparadas as Regressões Lineares Multivariadas (RLM) e Não Lineares (RNA). A RLM apresentada neste trabalho foi utilizada por Didoné (2009) para a formulação de uma equação, denominada por ela de Índice de Consumo de Iluminação Natural. Diante do melhor desempenho para a aproximação de funções das RNAs, salienta-se o potencial da utilização dessas para a modelagem de iluminação natural, visando à eficiência energética. Depois de validada, a RNA pode oferecer resultados de saída para dados de entrada que ainda não lhe foram apresentados. Isso pode ser feito através do programa MATLAB, utilizando apenas o modo progressivo (alimentado adiante) ou viabilizando a utilização da rede por meio de planilha eletrônica. Por fim, conclui-se que a análise conduzida neste

capítulo cumpriu com o seu objetivo, respondendo às perguntas de pesquisa apresentadas no item 4.2, como segue.

As RNAs conseguem modelar todas as variáveis-chave propostas por Didoné (2009), incluindo a orientação? (pergunta 1)

Sim. Comparando o R^2 obtido pela RLM com o obtido pela RNA, pode-se perceber uma melhora no coeficiente de determinação. Para a RLM, quando considerado todo o conjunto de dados, obteve-se um $R^2 = 0,6243$. Reduzindo esse conjunto, considerando apenas 95% dos casos, conseguiu-se uma melhora, chegando a $R^2 = 0,8028$. Já com a utilização de RNA, considerando todo o conjunto de dados, o R^2 médio das 10 rodadas de validação foi de 0,9867 (função *logsig*). Outro ponto importante é que a rede neural obteve esses resultados considerando a variável orientação. Esses resultados sinalizam que as RNAs podem ser mais consistentes para a representação dos modelos, no caso deste estudo.

Além disso, as RNAs apresentaram altos valores de coeficiente de correlação e determinação, bem como baixos valores de EQM e EAM. A média das 10 validações do EQM para a função *logsig* foi de 0,03, abaixo de 0,05, como recomenda a literatura. Com base nos resultados obtidos, as RNAs se mostraram uma alternativa a ser explorada para a aproximação de funções. Para este estudo comparativo, as RNAs apresentaram desempenho superior à RLM.

Qual a influência da função de transferência para modelar as variáveis-chave adotadas?(pergunta 2)

Não houve diferença significativa entre o desempenho dos modelos com funções de transferência logarítmica sigmoideal e tangente sigmoideal para afirmar que uma seria definitivamente mais adequada que a outra. Essa diferença mínima pode ser justificada por ambas por tratar-se de funções sigmoideais.

A diferença entre o desempenho das duas funções pode ser percebida de forma mais intensa nos resíduos (EQM) do que por meio dos coeficientes R^2 e R. A diferença entre o desempenho das funções será mais expressiva quanto mais ou menos adequada for a sua relação com a modelagem das variáveis da rede.

O quão efetivas as RNAs podem ser para generalizar resultados para casos com características arquitetônicas que não tivessem feito parte do conjunto dos modelos paramétricos? (pergunta 3)

A proposição do conjunto “nunca vistos” foi importante, pois mostrou a diferença na magnitude dos erros entre esse conjunto e o conjunto de teste com base na abordagem da literatura. No caso da RNA 3, a variação foi de 0,77% para o conjunto de teste (literatura) até 5% para o conjunto “nunca vistos”. Isso mostra que esse método é mais seguro ao se avaliar o poder de generalização da rede. Além disso, a investigação permitiu a indicação de pontos importantes a serem mais bem explorados ao longo do trabalho.

O estudo de Didoné (2009) contribuiu para a caracterização da modelagem do consumo energético visando à iluminação natural; entretanto, deixando algumas lacunas. Os pontos não abordados identificados para aprofundamento no presente trabalho são

- a verificação de variáveis-chave da iluminação natural;
- a consideração e a investigação da orientação dos ambientes;
- a inclusão da transmissão visível dos vidros; e
- a investigação da possibilidade de inclusão no modelo de variáveis-chave climáticas, permitindo que diferentes zonas bioclimáticas possam ser avaliadas no mesmo modelo.

5. INVESTIGAÇÃO SISTEMÁTICA DAS POTENCIALIDADES E DAS LIMITAÇÕES DAS RNAs – PARÂMETROS DO EDIFÍCIO

Este capítulo aborda uma investigação sistemática da metamodelagem das principais variáveis da descrição do edifício para a iluminação natural. Primeiramente, será apresentado um resumo da estrutura do capítulo contendo as perguntas de pesquisa relacionadas aos itens dos resultados e as ações realizadas para respondê-las. Em seguida, serão apresentados o esquema conceitual de aplicação do etapa 3 do método (com base no disposto na Figura 12, p. 103) aplicado a este capítulo e a descrição das ações. Os resultados serão apresentados segundo os grupos de ações realizadas para obtê-los.

5.1 INTRODUÇÃO

Como premissa para as investigações conduzidas neste capítulo, optou-se por iniciar o estudo com poucas variáveis a fim de tornar as observações viáveis. Foram selecionadas apenas as variáveis-chave primárias mais relevantes para a iluminação natural. Para as simulações computacionais, optou-se pela realização das simulações apenas no programa EnergyPlus. Como mencionado no capítulo de método geral, nessa etapa priorizou-se a agilidade na obtenção do conjunto de dados para treinar diferentes configurações de RNA à precisão. Quanto às redes neurais, decidiu-se por iniciar os testes com a rede mais simples que pudesse aprender padrões. Essas simplificações foram necessárias para permitir isolar o maior número de variáveis possível e observar o efeito de cada alteração independentemente.

5.2 DETALHAMENTO DO MÉTODO

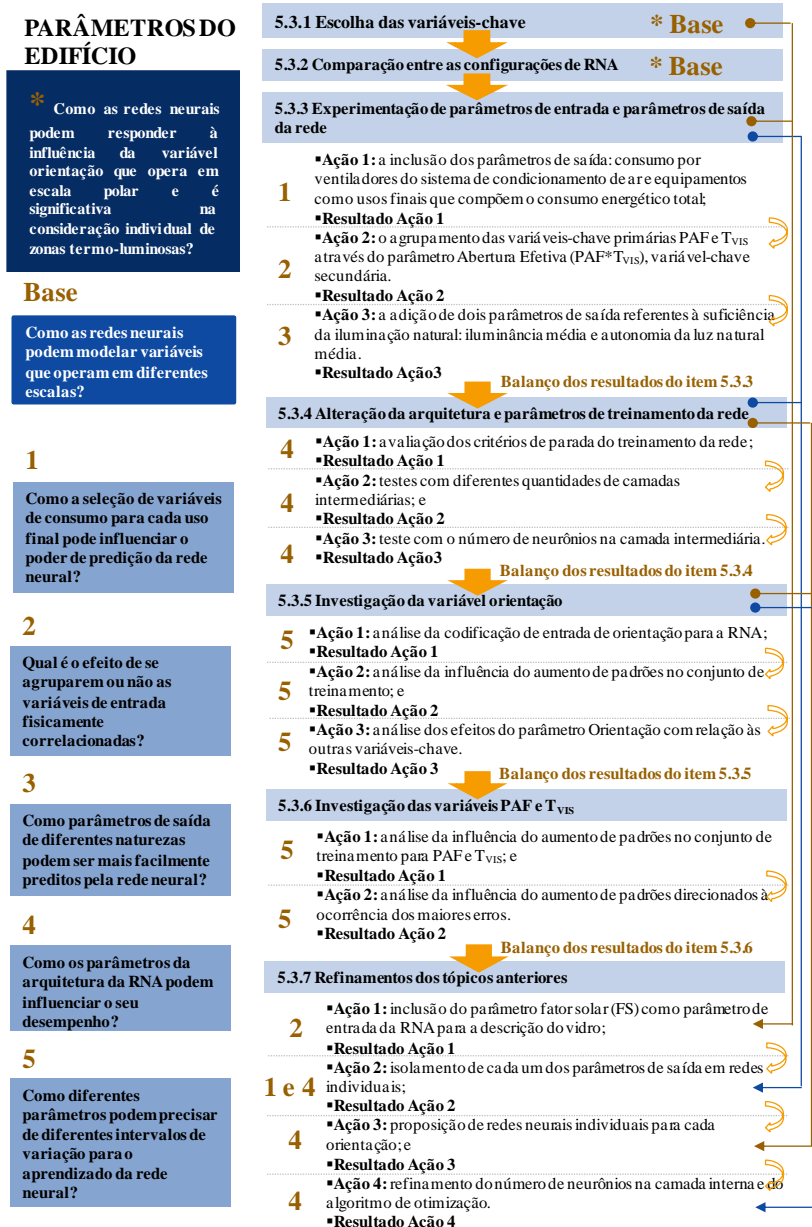
A Figura 21 apresenta a estrutura de desenvolvimento deste capítulo, destacando nos quadros azuis da coluna da esquerda as perguntas de pesquisa e na coluna da direita os itens dos resultados obtidos por meio das ações do método detalhado. As setas e as numerações ilustram a sequência da investigação sistemática relacionando itens com as perguntas de pesquisa destacadas da seguinte forma:

- no quadro azul marinho e simbolicamente representada por um asterisco, a principal pergunta de pesquisa que direcionou a proposição deste capítulo, descrita no item 3.2, p.105;

- no quadro de azul intermediário e representada pela palavra BASE, uma segunda pergunta, derivada da primeira e também estruturante do capítulo; e
- numeradas de um a cinco, as perguntas secundárias de pesquisa que nortearam o desenvolvimento da investigação abordada neste capítulo.

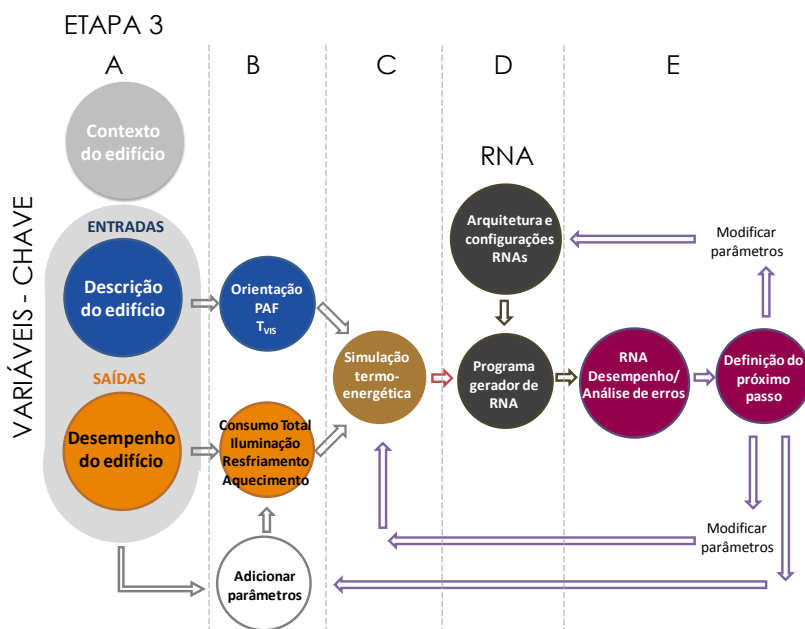
As setas curvas alaranjadas indicam a relação sequencial entre o resultado de uma ação e a estruturação da ação seguinte. As setas alaranjadas hachuradas indicam a transposição de um item (composto por várias ações) para o próximo item. As setas retas da lateral direita relacionam itens e/ou ações não imediatamente sequenciais e foram diferenciadas por cores apenas para facilitar a visualização.

Figura 21 – Resumo do processo da avaliação sistemática: descrição do edifício



Para responder às perguntas de pesquisa, adotaram-se as ações metodológicas apresentadas na Figura 22. Primeiramente, isolaram-se os grupos das variáveis-chave que seriam trabalhadas, neste caso, da descrição do edifício e do desempenho do edifício. As variáveis do contexto do edifício foram definidas e mantidas fixas de forma a não interferirem nas análises. As variáveis do desempenho do edifício foram tratadas superficialmente, pois exercem papel secundário nesta etapa do trabalho. Essas variáveis são estudadas de forma aprofundada no Capítulo 7.

Figura 22 – Aplicação da etapa metodológica 3: descrição do edifício

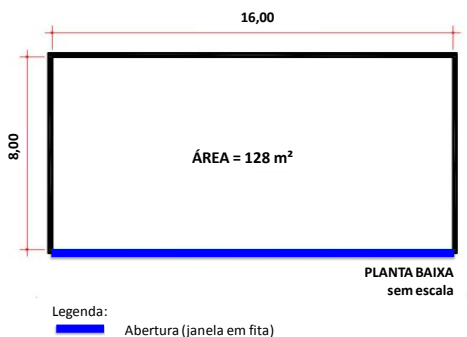


Fonte: Autor.

A escolha das variáveis-chave da descrição do edifício baseou-se na definição do quão críticas elas eram para a iluminação natural, focando especialmente em variáveis que não operassem no mesmo tipo de escala. O intuito dessa escolha foi de entender os efeitos de diferentes escalas quando apresentadas às redes neurais. As variáveis de desempenho abordaram os principais usos finais do consumo energético em edificações comerciais.

A geração dos dados para o treinamento da rede foi feito através de simulações paramétricas, utilizando-se a macro de Westphal (2012) adaptada e o programa EnergyPlus. As características construtivas, de uso e ocupação foram mantidas de acordo com a Tabela 2, p. 129, apenas a densidade de potência de iluminação foi alterada para $9,4 \text{ W/m}^2$. Somente uma geometria foi utilizada a partir da qual as variações paramétricas foram feitas. A geometria-base consistiu em um modelo retangular, de 16 m de comprimento por 8 m de profundidade e 3 m de pé-direito, correspondente a uma zona térmica (ver Figura 23). As proporções do ambiente foram definidas visando minimizar a principal limitação do EnergyPlus, de maximizar o efeito das reflexões da luz natural em ambientes profundos.

Figura 23 – Planta baixa da geometria-base utilizada neste capítulo



Fonte: Autor.

Para a operacionalização de uma rede neural extremamente simples, mas que pudesse aprender padrões, utilizou-se o programa EasyNN-plus (ver Apêndice B5, p.423). Esse programa permite gerar automaticamente a menor rede que possa aprender padrões de acordo com alguns dados de entrada fornecidos pelo usuário (WOLSTENHOLME, 2013c). Entretanto, para averiguar se as configurações padrão desse programa seriam equivalentes à configuração adotada no capítulo anterior usando o MATLAB, foi realizada uma comparação entre esta última configuração e a rede proposta pelo EasyNN-plus.

Os efeitos das perturbações nas redes neurais foram avaliados conforme análise de erros descrita no item 3.4.3 do método geral. Procurou-se sempre trabalhar com um número mínimo de padrões para cada parâmetro de entrada a fim de testar os limites das RNAs.

As ações conduzidas para responder às perguntas geradas foram separadas em cinco grupos:

- (1) experimentação de parâmetros de entrada e parâmetros de saída da rede;
- (2) alteração da arquitetura e parâmetros de treinamento da rede;
- (3) investigação da variável orientação como variável que opera em escala polar contínua;
- (4) exploração: tipos de variáveis-chave *versus* quantidade de parâmetros de entrada; e
- (5) refinamentos dos tópicos anteriores.

Os detalhes metodológicos da seleção de variáveis-chave, da comparação entre configurações de RNA e dos cinco grupos de ações listados são apresentados nos subitens a seguir (item 5.2.1 ao 5.2.7).

5.2.1 Escolha das variáveis-chave

Para a escolha das variáveis-chave, determinaram-se quais grupos da Figura 3, p.61, faziam parte da descrição do edifício e, dentro desses grupos, elencaram-se três variáveis críticas para a iluminação natural. O mesmo foi feito para a seleção das variáveis de desempenho do edifício, considerando as variáveis de saída apresentadas na Figura 3 e focando nos impactos energéticos.

5.2.2 Comparação entre as configurações de RNA

Para a comparação entre as configurações das redes neurais (MATLAB x padrão EasyNN-plus), definiu-se e simulou-se (EnergyPlus) um novo conjunto de modelos paramétricos que serviria para o aprendizado da rede. Foram geradas 10 redes neurais para cada solução.

Para tal, definiram-se os valores a serem atribuídos a cada variável-chave, procurando selecionar valores altos, baixos e intermediários a fim de obter convergência da rede. Definiram-se os modelos para o teste do conjunto “nunca vistos”, buscando intercalar os valores escolhidos para o treinamento. Para que as variações do conjunto de teste pudessem ser observadas, adotou-se um modelo-base do conjunto de treinamento a partir do qual as alterações foram feitas individualmente.

Para os treinos no MATLAB, as características da rede do capítulo anterior foram mantidas (PMC – retropropagação do erro – Gradiente Descendente adaptativo – *logsig* – validação cruzada – uma

camada intermediária – 10 neurônios ocultos). Entretanto, as variáveis de entrada foram substituídas pelas três variáveis-chave escolhidas. O consumo energético total, que era o único parâmetro de saída da rede, foi somado a mais três parâmetros de saída (variáveis de desempenho escolhidas). O critério de parada foi o número máximo de épocas, 100.000. A validação cruzada manteve o critério de divisão do conjunto de dados 9/10 para treinamento e 1/10 para teste. Das 10 RNAs geradas, foram selecionadas as duas com maior e menor erro para serem testadas com o conjunto “nunca vistos” e comparadas com a solução do EasyNN-plus.

O EasyNN-plus também trabalha com PMC retropropagação do erro – logarítmica simoidal –, sendo o algoritmo de otimização o Gradiente Descendente. Adotaram-se os mesmos padrões de entrada, saída e critério de parada da rede do MATLAB. Para a seleção de neurônios na camada oculta, utilizou-se a função do programa que sugere um número mínimo de neurônios que permita o aprendizado da rede. O conjunto de dados foi dividido conforme o método da literatura, como explanado no item 3.4.3, e as redes também foram testadas com o conjunto “nunca vistos”.

5.2.3 Experimentação de parâmetros de entrada e parâmetros de saída da rede

Para este conjunto de ações, partiu-se da mesma configuração de rede neural utilizada no item 5.2.2 para o programa EasyNN-plus. A partir das observações da rodada anterior, buscou-se verificar os efeitos de adição de parâmetros de saída que compõem o consumo energético total da edificação. Como o ajuste dos pesos da rede neural é um processo “caixa-preta”, procurou-se observar se, ao tentar aproximar as respostas a esses novos padrões de saída, o ajuste dos pesos poderia melhorar a resposta geral da rede. Para isso, tais parâmetros de saída foram adicionados à rede e a sequência de ações descritas no início do método neste capítulo, ilustrada na Figura 22, p. 150, foi aplicada. As análises dos resultados dessa etapa levaram à próxima ação, que buscou verificar como o desempenho da rede seria alterado mediante o agrupamento de variáveis de entrada fisicamente correlacionadas. Nesse passo, as variáveis de entrada foram analisadas e agrupadas, então novamente se repetiu o processo da Figura 22. Por fim, observou-se introdutoriamente o potencial das RNAs em modelar parâmetros de saída de diferentes naturezas. Nessa etapa, incluíram-se parâmetros de saída relacionados à quantificação da iluminação natural e repetiu-se a

mesma sequência metodológica novamente. A verificação dos parâmetros de saída como medidas de desempenho do edifício foi estudada mais profundamente no Capítulo 7.

5.2.4 Alteração da arquitetura e parâmetros de treinamento da rede

Como já mencionado, dos fatores que afetam a capacidade de generalização da RNA, têm-se a arquitetura da rede e o número de neurônios nas camadas ocultas. Diante disso, esse conjunto de ações abordou a análise da influência desses parâmetros. Tornou-se a aplicar a sequência metodológica da Figura 22, p. 150, partindo-se da RNA da última intervenção do item anterior. É importante ressaltar que, nessa etapa, apenas a sequência da segunda metade da figura foi repetida. Como as alterações foram feitas somente nos parâmetros da rede neural, não foram necessárias novas simulações computacionais energéticas. Primeiramente, foi testado o efeito de diferentes critérios de parada de treinamento, em seguida o número de camadas ocultas e, por fim, o número de neurônios nas camadas ocultas, conforme item 3.4.3 do método geral. Os critérios e a justificativa da escolha são apresentados no Quadro 2.

A última opção apresentada no Quadro 2 surgiu durante o processo como uma derivação da opção de parada por número de ciclos. Essa opção baseou-se em definir o número de ciclos através da observação dos gráficos de treinamento de redes anteriores. Para essa avaliação, fixou-se o início do treinamento da rede no mesmo ponto da superfície do erro para todas as redes.

Quadro 2 – Critérios adotados para a interrupção do treinamento da rede e sua respectiva justificativa

PARAR QUANDO ou SE...	CRITÉRIO ADOTADO	JUSTIFICATIVA
O erro está abaixo no alvo X...	Erro médio de validação	O erro médio do conjunto de validação normalmente é mais elevado que o do treinamento; logo, parando o treinamento segundo o conjunto de validação, há mais chances de a RNA apresentar boa generalização.
O erro está aumentando...	Erro médio de validação	A verificação é feita a cada seis ciclos. Identificação de mínimos locais e mínimos globais (ver item 2.3.6.1).
Número de ciclos.	100.000 ciclos (épocas)	O mesmo número de ciclos adotado para as RNAs do MATLAB no capítulo anterior.
Menor erro de validação quando a RNA for treinada com...	100.000 ciclos (épocas)	Embora esta opção não seja padrão do programa, permite tirar partido de uma de suas ferramentas: os gráficos de treinamento atualizados em tempo real.

Fonte: Autor adaptado de: Wolstenholme (2013b).

Para a investigação da influência do número de camadas intermediárias (ocultas), escolheu-se um critério de parada conforme a etapa anterior e geraram-se redes com uma, duas e três camadas internas, de acordo com a disponibilidade do programa. Para a escolha do número de nós em cada camada interna, utilizou-se a opção do programa em que se definem o número mínimo e o máximo de neurônios por camada, e o próprio programa indica o número de neurônios de acordo com o processo descrito no Apêndice B5, p.423. Definiram-se dois neurônios como mínimo e 10 como máximo. Como última verificação, simulou-se a opção de rede com uma camada interna, permitindo a reconfiguração do número de neurônios da rede durante o treinamento.

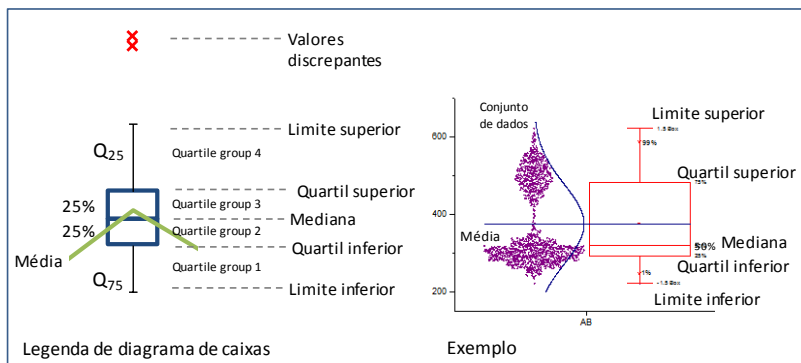
Para a verificação da influência do número de neurônios no modelo, testou-se a configuração de uma camada oculta com dois, quatro, seis, oito e 10 neurônios. A intenção foi iniciar-se com o número mínimo de neurônios na camada intermediária. O programa não permitiu a opção de um só nó. Utilizaram-se gráficos do tipo diagrama de caixas para facilitar as análises. A Figura 24 ilustra um diagrama de caixas legendado. Neste trabalho eles serão apresentados na vertical. Esse tipo de diagrama permite uma visualização melhor da distribuição estatística dos dados, possibilitando a observação de onde ocorrem a maior e a menor distribuição dos dados, da simetria da distribuição e da

existência de valores discrepantes. Essas informações são obtidas através dos valores extremos máximo e mínimo, do primeiro e do terceiro quartis e da mediana. São considerados valores discrepantes os valores abaixo da barreira do quartil inferior (Q_{25}) e acima da barreira do quartil superior (Q_{75}). Para a definição dessas barreiras, utilizaram-se as Equações 24 e 25.

$$\text{BarreiraInferior} = Q_{25} - 1,5 * (Q_{75} - Q_{25}) \quad (24)$$

$$\text{BarreiraSuperior} = Q_{75} + 1,5 * (Q_{75} - Q_{25}) \quad (25)$$

Figura 24 – Diagrama de caixas legendado (Box plot ou Box-and-Whisker Charts)



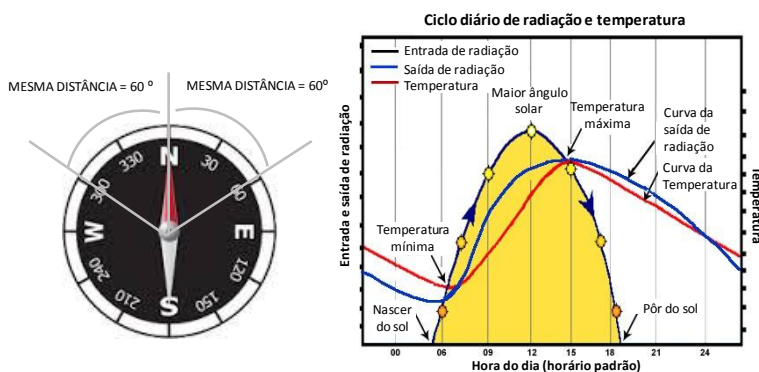
Fonte: Adaptado de: Creative Commons (2013) e Priddles Priddle (2014).

5.2.5 Investigação da variável orientação

As ações deste grupo foram iniciadas pela investigação da codificação da variável orientação como variável que opera em escala polar para a rede neural. Todas as ações seguiram o método da Figura 22, p. 150, baseando-se nas redes das ações anteriores. Assim, primeiramente, foram propostas redes com o azimute como código de entrada para orientação, considerando-se as quatro orientações cardeais (N, S, L e O). A bibliografia oferece uma abordagem para variáveis

cíclicas em que o ângulo é codificado com o valor absoluto da diferença entre o ângulo considerado e um ângulo de referência (ver Figura 25a). Como exemplo, a orientação Norte (0°) poderia ser considerada o ângulo de referência. Assim, a orientação 359° N e a orientação 1° N teriam a mesma entrada, 1° , para a rede neural. Essa abordagem seria indicada se não houvesse diferença entre a temperatura externa acumulada durante o dia para as fachadas Leste e Oeste (ver Figura 25b). Entretanto, a solução foi testada a fim de se comparar o desempenho dessa abordagem com a anterior. Por fim, retomou-se a abordagem azimutal, mas dessa vez acrescentando modelos orientados a 359° N ao conjunto de treinamento a fim de informar a rede da característica polar da escala. As análises foram feitas através de gráficos radiais do Excel.

Figura 25 – Abordagens para variáveis cíclicas (ou polares)



(a) Abordagem da área da computação.

(b) Limitação pelo efeito do fenômeno térmico.

Fonte: Adaptado de: Baker (2013).


A segunda ação deste grupo foi a investigação de como o desempenho da rede poderia ser afetado aumentando-se o número de exemplos de diferentes orientações na fase de treinamento. A codificação utilizada foi a azimutal + 359° N. Essa ação foi realizada em duas etapas: na primeira, foram acrescentadas as orientações colaterais (NE, SE, NO e SO); e, na segunda, foram acrescentadas as orientações subcolaterais (NNE, ENE, ESE, SSE, SSO, OSO, ONO e NNO). As análises foram feitas através de gráficos do tipo diagrama de caixas.

A última ação deste grupo consistiu em uma análise dos efeitos do parâmetro orientação relacionado com as outras duas variáveis-chave no fenômeno termoluminoso que se reflete no consumo energético total. Essa análise se fez necessária a fim de identificar particularidades do fenômeno que poderiam facilitar ou dificultar o aprendizado da rede dependendo dos padrões de entrada escolhidos.

Para tal, a análise baseou-se apenas na primeira parte do esquema metodológico da Figura 22, p. 150, ou seja, nessa etapa não se utilizaram redes neurais. O mesmo conjunto de variações que vinha sendo trabalhado foi simulado, considerando-se um ambiente profundo. A mesma geometria foi adotada; entretanto, a abertura foi relocada para uma das superfícies de menor área. Assim, foram comparados ambientes de proporção “2 x 1” (ambiente largo) e “1 x 2” (ambiente profundo) para 17 orientações (cardeais, colaterais, subcolaterais e 359 N).

Os resultados de consumo energético total foram plotados em gráficos de pontos e gráficos de bolhas (ver Figura 26), que permitiram identificar particularidade do fenômeno que poderia exigir maior atenção na definição dos padrões de entrada da rede.

Figura 26 – Aplicação dos gráfico bolha para avaliar a inter-relação das variáveis frente ao fenômeno



Legenda:

Variável de entrada 1: variação de cor (abscissas, eixo X)

Variável de entrada 2: variação do tom das cores (transparência) das bolhas

Variável de entrada 3: variação do tamanho das bolhas

Variável de saída: eixo das ordenadas (eixo Y)

Fonte: Autor.

5.2.6 Exploração: tipos de variáveis-chave *versus* quantidade de parâmetros de entrada

Neste grupo, explorou-se como diferentes tipos de variáveis-chave poderiam precisar de diferentes quantidades de parâmetros na fase de treinamento da rede para melhorar a precisão dos resultados. Para tanto, seguiu-se com a sequência metodológica da Figura 22, p. 150.

Semelhante ao teste que foi feito para orientação, foram definidos valores intermediários para cada uma das outras variáveis-chave. Iniciou-se o treinamento da rede com apenas dois valores extremos da variável-chave a ser observada. Em uma segunda etapa, acrescentou-se um valor intermediário e, por fim, valores intermediários aos três primeiros. A divisão dos conjuntos de dados foi feita de acordo com o método da literatura, e, a cada etapa em que valores intermediários eram acrescentados, a divisão era refeita de forma aleatória. Essa sequência de treinamento foi repetida para os valores apresentados em ordem ou randomicamente à RNA. Quando se altera a forma de apresentação dos dados, novas redes são geradas, dobrando-se o número de redes.

Elaborou-se um conjunto com valores que não tinham sido incluídos nas combinações paramétricas para os testes com o conjunto “nunca vistos”. Além disso, os casos a serem incluídos no treinamento em cada etapa, enquanto não eram usados para o treinamento, foram aplicados na fase de testes da rede. Na leitura dos resultados procurou-se separar os conjuntos de “testes temporários” e o conjunto de “teste fixo” (“nunca vistos”). Este último foi o que serviu para comparar o efeito do aumento de exemplos das variáveis no desempenho da rede.

As tendências dos erros foram observadas através de gráficos de linhas, permitindo a visualização dos resultados de cada uma das 10 RNAs; em barras, a observação das médias dos erros para cada parâmetro de saída; em pontos, a observação da inclusão dos novos valores para as variáveis; e em bolhas, a observação dos possíveis gargalos do fenômeno no treinamento da rede.

Como segunda ação deste grupo, procurou-se incluir no treinamento da rede novos valores para as variáveis-chave, conforme o ponto onde foram observados os maiores erros. Essa medida serviu para verificar se a adição desses valores ajudaria a rede a melhor aprender esses padrões e melhorar o seu poder de generalização.

Para essa ação, foram observados os resultados da ação anterior para ambas as variáveis-chave e identificados os maiores erros. Definiram-se os novos valores para cada uma delas, considerando que fossem valores próximos aos que geraram esses erros. Novos modelos

paramétricos foram elaborados, simulações energéticas foram feitas e novas redes neurais, incluindo esses padrões no conjunto de treinamento, foram geradas. As características das simulações, do treinamento das redes e das análises dos resultados seguiram a mesma padronização da ação anterior.

5.2.7 Refinamentos dos tópicos anteriores

Este conjunto engloba quatro ações principais, três delas para avaliar questões sobre parâmetros de entrada e parâmetros de saída da rede. A última visou verificar a aplicabilidade de diferentes algoritmos de treinamento para a rede. Para esta ação, voltou-se a utilizar o programa MATLAB, que permite maior flexibilidade na programação das redes.

Para os testes elaborados nesta etapa do trabalho, as simulações energéticas dos conjuntos de ações anteriores foram aproveitadas e novas redes neurais foram propostas segundo o objetivo da investigação.

A primeira ação consistiu em verificar o impacto ao complementar a descrição de um elemento da edificação através da adição de mais uma variável-chave. Para isso, aproveitaram-se as simulações energéticas do grupo de ações do item 5.2.6 e propuseram-se novas redes neurais (10 redes), dessa vez acrescentando-se uma quarta variável-chave à camada de entrada da RNA.

Na segunda ação propuseram-se redes isolando-se os parâmetros de saída. A intenção foi verificar o que aconteceria com a rede ao ter que prever apenas um padrão de saída. Uma hipótese seria que o aprendizado da rede seria simplificado e seu desempenho melhorado. A outra hipótese, previamente testada no item 5.2.3, seria de que, ao tentar aproximar as respostas a padrões de saída correlacionados, o ajuste dos pesos (ver item 2.3.6, p. 83) poderia melhorar a resposta geral da rede.

Para isso, foram geradas redes neurais, todas com as mesmas configurações, os mesmos padrões de entrada e o mesmo número de neurônios na camada oculta, variando apenas o parâmetro de saída (10 redes para cada parâmetro de saída). Foram aplicados o mesmo método de divisão de conjuntos para o treinamento, método da literatura, e a mesma apresentação dos dados à rede (ordenada ou randômica) do item 5.3.3.

Como a orientação foi o parâmetro crítico e motivador das perguntas iniciais deste capítulo, na terceira ação propuseram-se redes neurais individuais para cada orientação. Para tal, agruparam-se os resultados das simulações energéticas do item 5.2.2, p. 152, segundo a

orientação. Em seguida, treinaram-se 10 redes neurais para cada orientação com as mesmas configurações, os mesmos padrões de entrada, o mesmo método de divisão de conjuntos de treinamento e a apresentação dos dados do item 5.2.3, p. 153.

Desde o início deste capítulo até esta ação, o número de neurônios ocultos utilizados foi o indicado pelo EasyNN-plus, considerando-se a rede mais simples que pudesse aprender, baseada no algoritmo do Gradiente Descendente, o padrão do programa. Assim, nesta quarta ação, testou-se a mesma configuração de rede do item 5.2.3, mas alterando o número de neurônios da camada interna, utilizando-se duas soluções heurísticas apresentadas no capítulo de revisão bibliográfica, os teoremas de Hecht-Nielsen e de Upadhyaya-Eryurek. As equações utilizadas correspondem à Equação 6, p. 82, e à Equação 7, p. 83, respectivamente.

Depois do teste com o novo número de neurônios na camada oculta, testaram-se os algoritmos de otimização Levenberg-Marquardt e Regularização Bayesiana. Nesta etapa retomou-se o programa MATLAB, que permite a programação de redes com essas funções.

5.3 RESULTADOS

Primeiramente, são apresentados os resultados da escolha das variáveis-chave e, em seguida, os resultados da comparação entre a solução de rede do MATLAB, baseada nas RNAs do Capítulo 4, e a solução de rede, proposta pelo programa EasyNN-plus. E, então, são apresentados os resultados dos cinco grupos, descritos do item 5.2.3 ao item 5.2.7.

5.3.1 Escolha das variáveis-chave

A primeira variável-chave escolhida foi a Orientação, visto que foi a motivadora das primeiras perguntas de pesquisa. A definição das outras variáveis atendeu aos seguintes critérios: importância para o fenômeno da iluminação natural, escala e natureza.

Nesse sentido, as variáveis escolhidas foram Percentual de Abertura da Fachada (PAF) e Transmissão Visível (T_{VIS}), pois foram consideradas as variáveis de maior impacto para a iluminação natural e o consumo energético (SHEN; TZEMPELIKOS, 2012). De certa forma, são variáveis básicas para a descrição da fonte de luz (janela).

Adicionalmente, ambas as variáveis operam em escala proporcional²¹ contínua,²² mas representam propriedades diferentes da fonte de luz. O PAF é uma propriedade geométrica e referente ao tamanho da fonte, e a T_{VIS} é uma propriedade do material (transmissão da fonte).

Como variáveis de desempenho, inicialmente foram selecionadas apenas as variáveis de impacto energético: consumo total, consumo para resfriamento, aquecimento e iluminação. Em determinado momento da investigação utilizaram-se como medidas de suficiência de iluminação natural a iluminância média do ambiente e a autonomia da luz natural média. Sabe-se que essas medidas, isoladamente, não são adequadas para a avaliação do ambiente luminoso, pois não dão ideia da espacialidade da distribuição da luz. Entretanto, o EnergyPlus oferece como resultado apenas iluminâncias horárias para cada ponto e o usuário deve processá-las; assim, procurou-se simplificar essa avaliação, mesmo porque essas variáveis serão abordadas mais detalhadamente no Capítulo 7.

Para isolar as variáveis do contexto do edifício, foi fixada uma localidade; assim, todas as simulações deste capítulo foram realizadas com arquivo climático da cidade de Florianópolis.

De acordo com a classificação de Heshong (2011), exposta na Figura 3, p.61, a variável Orientação faz parte do grupo A (descrição do espaço), as variáveis PAF e T_{VIS} do grupo B (descrição da fenestração), as variáveis de suficiência de iluminação do grupo 1 (conforto humano) e as variáveis de consumo do grupo 2 (impactos energéticos). As demais variáveis, quando aplicáveis, foram mantidas constantes.

5.3.2 Comparação entre as configurações de RNA

De acordo com as variáveis-chave selecionadas, a arquitetura da rede neural utilizada nessa comparação foi composta de três neurônios na camada de entrada (Orientação, PAF e T_{VIS}) e quatro na camada de saída (Consumo Total, Consumo para Resfriamento, Aquecimento e

²¹ Escala proporcional: é uma forma quantitativa de registrar um fenômeno, medindo-o em termos da sua intensidade específica, ou seja, posicionando-o em relação ao zero absoluto (total ausência de uma característica ou propriedade). Cada observação é aferida segundo a sua distância ao ponto zero, distância essa expressa na unidade de medida previamente definida. Destaca-se que nas escalas proporcionais um valor "2" indica, efetivamente, uma quantidade duas vezes maior do que o valor "1", o que não acontece, necessariamente, nas escalas nominal, ordinal e intervalar (MORAIS, 2005).

²² Escala contínua: os seus valores podem assumir qualquer valor real dentro de um intervalo.

Iluminação). Para as simulações no MATLAB, mantiveram-se 10 neurônios distribuídos em uma camada intermediária (ver capítulo anterior). Para o EasyNN-plus, utilizou-se a ferramenta do programa que define o número de neurônios, tendo sido definidos seis. As combinações paramétricas para o conjunto de treinamento foram obtidas através da combinação dos seguintes valores: as quatro orientações cardeais (N, S, L e O); o PAF (20%, 50% e 80%); e a T_{VIS} (45%, 54%, 74% e 88%). Para o conjunto de teste, utilizou-se um modelo-base (Norte, PAF 50% e T_{VIS} 88%) a partir do qual foram feitas as alterações de cada uma das variáveis por vez. Dessa forma, foi possível avaliar o efeito da generalização para cada uma delas. Os valores adotados para o conjunto “nunca vistos” foram as quatro orientações colaterais (NE, SE, NO e SO); o PAF (23%, 65% e 90%); e a T_{VIS} (25%, 57%, 74% e 91%).

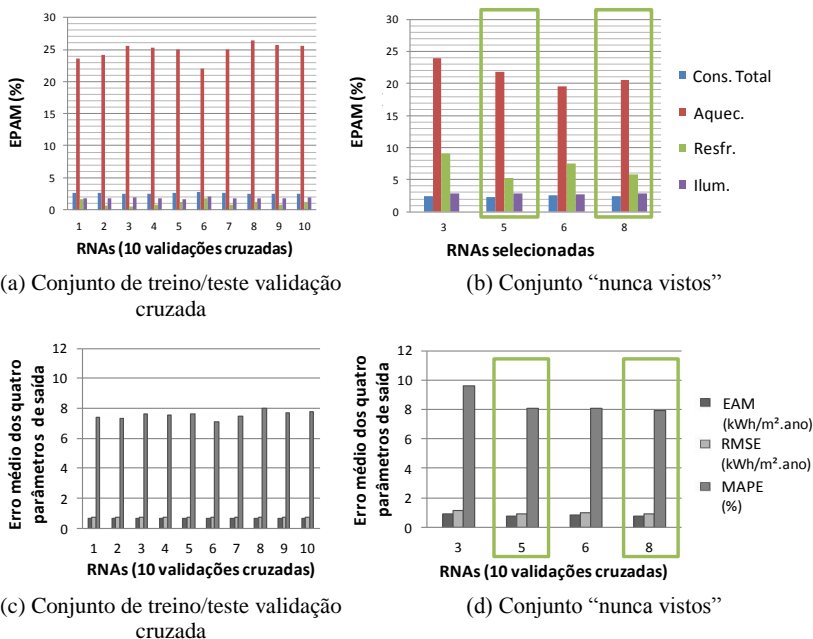
Os vidros foram selecionados a partir da biblioteca do programa EnergyPlus. As aberturas foram consideradas de uma lateral à outra (tipo fita), com verga a 2,7 m do piso e altura de 0,30 m. Para a variação do PAF, alterou-se apenas a altura do peitoril. O PAF de 90% foi escolhido para forçar uma extrapolação. Segundo a bibliografia, as RNAs têm grande poder de generalização, mas pequeno de extrapolação. Com isso, procurou-se testar um dos limites das RNAs.

Primeiramente, foram treinadas as redes do MATLAB. Como o método da validação cruzada seleciona diferentes porções do conjunto de dados para cada uma das 10 redes, todos os resultados foram analisados para a escolha das redes neurais a serem adotadas na comparação. Os resultados de EAM, EPAM e EQM para as 10 rodadas da validação cruzada foram os primeiros a serem avaliados. Os erros percentuais para Consumo por Aquecimento foram extremamente elevados, conforme mostra a Figura 27a; esse padrão poderá ser observado ao longo de todo o trabalho. Isso ocorre porque os valores de consumo para aquecimento em Florianópolis são muito baixos, fazendo com que pequenos valores absolutos tornem-se grandes valores percentuais. As redes 3, 5 e 8 apresentaram os menores erros percentuais para Resfriamento, Iluminação e Consumo Total, respectivamente (ver Figura 27a). Enquanto a RNA 3 apresentou menor erro absoluto e quadrático para a média dos quatro parâmetros de saída (ver Figura 27c e d), a RNA 6 apresentou o menor EPAM (ver Figura 27a). Entretanto, foi atribuído à RNA 6 o pior desempenho para todos os parâmetros de saída, com exceção do Aquecimento. Como em percentual esse é o erro mais expressivo, ele forçou a média para baixo.

Sendo assim, escolheram-se essas quatro redes – RNA 3, 5, 6 e 8 – para serem testadas novamente, mas agora com o conjunto “nunca

vistos”. De acordo com a Figura 27b, a rede 5 apresentou os menores EPAMs para Consumo Total e Resfriamento, a rede 6 para Aquecimento e Iluminação e a rede 8 a menor média entre os erros dos quatro parâmetros de saída. A rede 3 apresentou os maiores erros para todos os parâmetros de saída, com exceção do Consumo Total. As redes 5 e 8, destacadas com a moldura verde, foram as escolhidas para a comparação com os resultados do EasyNN-plus. Considerando-se a média dos erros dos quatro parâmetros de saída, a rede 5 foi a que apresentou o menor erro absoluto e a rede 8 o menor erro quadrático e EPAM.

Figura 27 – Comparação entre as redes da valiação cruzada do Matlab: (a) e (b) separado por uso final; e (c) e (d) média dos usos finais (rede completa) para os mesmos conjuntos.

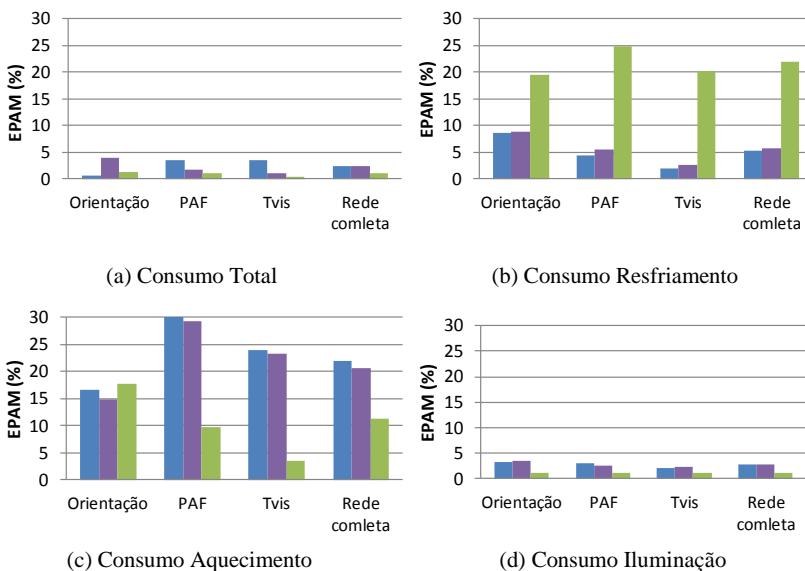


A comparação entre as três soluções (RNA5-MATLAB, RNA8-MATLAB e RNA_{média}-EasyNN-plus) foi feita com base em cada uso final e para cada variável-chave do conjunto “nunca vistos”. Priorizou-se esse conjunto, pois, em todos os casos, apresentou um erro muito superior ao dos conjuntos de treinamento/validação/teste, o que significa


que, em todos os casos, as redes convergiram bem, mas não foram capazes de estender o mesmo desempenho para a generalização.

A média das redes neurais baseada no EasyNN-plus, em geral, apresentou menores erros que as configurações adotadas no MATLAB, com exceção do Consumo para Resfriamento para as três variáveis-chave e para o conjunto total, e do Consumo para Aquecimento para Orientação (ver Figura 27). Para Resfriamento, a solução do EasyNN-plus apresentou EPAM em média quatro vezes maior que as outras duas RNAs (ver Figura 28b). Já a diferença do Aquecimento foi um pouco maior que 1% em relação à RNA5-MATLAB (ver Figura 28c).

Figura 28 – Comparação entre as duas redes de melhor desempenho do Matlab e a rede do EasyNN para cada variável-chave de entrada agrupadas por uso final para o conjunto “nunca vistos”



Legenda:



Analisando-se os resultados da solução do EasyNN-plus de acordo com as variáveis-chave para os quatro parâmetros de saída, com exceção do Consumo por Resfriamento, pode-se observar uma

hierarquia dos erros, sendo os maiores atribuídos à Orientação, seguidos de PAF e T_{VIS} .

As principais diferenças entre as redes neurais do MATLAB deste capítulo e as redes do Capítulo 4 são a quantidade de padrões no treinamento e os parâmetros de saída. Naquele capítulo só foi considerado o Consumo Total, que era a variável de desempenho de Didoné (2009). Entretanto, é importante destacar que o desempenho das redes neurais foi aproximado quando considerado apenas esse parâmetro de saída. A diferença entre o desempenho das RNAs ao estimar o Consumo Total e os outros parâmetros de saída pode ser justificada pelo fato de o Consumo Total ser um balanço das influências da luz e do calor nos consumos de iluminação e condicionamento de ar. Todas as redes apresentaram erros maiores para a previsão do Consumo por Resfriamento (o aquecimento foi desconsiderado devido aos seus valores absolutos muito baixos). Entende-se que, ao considerar a influência da iluminação natural no condicionamento de ar, o fenômeno a ser aprendido pela rede torna-se mais complexo (balanço entre ganho térmico exterior e interior do sistema de iluminação artificial). Com isso, devem-se fornecer mais subsídios à rede a fim de que ela possa generalizar melhor.

Uma diferença entre as configurações do MATLAB e do EasyNN-plus foi o fato de que para as primeiras adotou-se o algoritmo de otimização Gradiente Descendente com taxa de aprendizado adaptativo e para as outras apenas Gradiente Descendente. Apesar de haver mais variáveis que diferem uma configuração da outra, optou-se por conduzir as próximas etapas com Gradiente Descendente.

Apesar de a solução do EasyNN-plus ter apresentado maiores valores de EPAM que o MATLAB para a previsão do consumo para resfriamento, julgou-se ser uma opção aceitável para a condução dos demais testes deste capítulo, pois, para os demais parâmetros de saída, seu desempenho foi superior (menores valores de EPAM) aos das outras soluções. Destaca-se a previsão do consumo de iluminação, que é o sistema com padrão de uso diretamente influenciado pela iluminação natural, quando aproveitada.

5.3.3 Experimentação de parâmetros de entrada e parâmetros de saída da rede

Conforme descrito no item 5.2.3, as três ações realizadas neste conjunto foram:

- (1) a inclusão dos parâmetros de saída: Ventiladores (consumo por ventiladores do sistema de condicionamento de ar) e equipamentos como usos finais que compõem o consumo energético total;
- (2) o agrupamento das variáveis-chave primárias PAF e T_{VIS} através do parâmetro Abertura Efetiva ($PAF * T_{VIS}$), variável-chave secundária; e
- (3) a adição de dois parâmetros de saída referentes à suficiência da iluminação natural: iluminância média e autonomia da luz natural média.

Como nesse conjunto de ações foram alterados apenas os parâmetros da entrada e saída da rede neural, aproveitaram-se as simulações energéticas do EnergyPlus do item anterior (5.3.2). As redes neurais foram geradas no EasyNN-plus, e, com exceção das variáveis de entrada e saída manipuladas, as demais configurações da rede do item 5.3.2 foram mantidas.

5.3.3.1 *Resultados da ação 1 – a inclusão dos parâmetros de saída: Ventiladores*

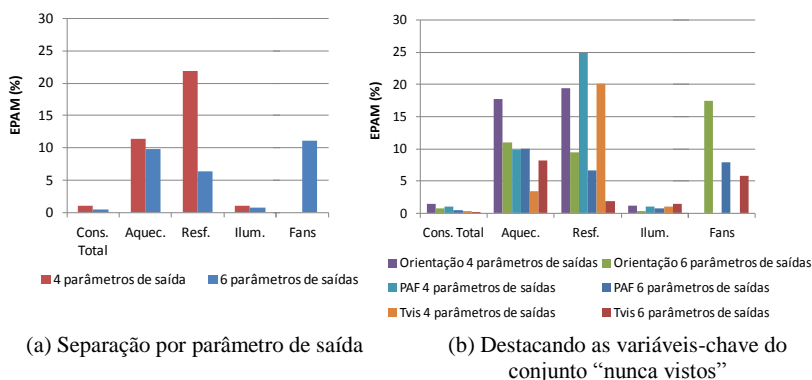
Como os valores dos padrões do parâmetro de saída Equipamentos eram constantes (o consumo não variava), o programa não aceitou a inclusão desse parâmetro na arquitetura das redes neurais. Logo, as redes foram testadas com cinco neurônios na camada de saída, os quatro da etapa anterior e Ventiladores.

A adição desse parâmetro, em geral, melhorou o desempenho da rede para todos os parâmetros de saída (ver Figura 29a). Essa melhora pode ser percebida em especial para Resfriamento. Entretanto, o próprio parâmetro Ventiladores apresentou erros maiores que 10%. Observando a Figura 29b, pode-se notar que a adição desse parâmetro de saída melhorou as predições da rede para as três variáveis-chave – orientação, PAF e T_{VIS} – para o conjunto “nunca vistos”. Contudo, essa melhora é menos percebida para o parâmetro de saída Consumo por Iluminação.

Esses resultados levam a crer que a inclusão do parâmetro de saída Ventiladores influenciou positivamente o ajuste dos pesos (caixa-preta) da rede neural. Os erros da previsão do Resfriamento parecem ter sido “divididos” entre resfriamento e ventilação (as duas partes que compõem consumo de refrigeração do condicionamento de ar). O desempenho do Aquecimento, que também faz parte do consumo do sistema de condicionamento de ar, foi o segundo mais influenciado pela adição do parâmetro Ventiladores. O consumo de iluminação que

influencia o consumo dos ventiladores, mas que não é influenciado por ele, mostrou-se pouco sensível à alteração e, observando o resultado de cada padrão de saída individualmente, em alguns casos, a adição de Ventiladores aumentou o erro (ver Figura 29). Considerando-se a soma dos EPAM de todos os parâmetros de saída, ou seja, o erro geral da rede, a adição desse parâmetro piorou o desempenho do conjunto de treinamento/validação (de 2,1% para 2,8%), mas melhorou o desempenho do conjunto “nunca vistos” (de 8,3% para 5,7%).

Figura 29 – Verificação do efeito da inclusão de *Ventiladores* como parâmetro de saída nas redes



5.3.3.2 Resultados da ação 2 – o agrupamento das variáveis-chave primárias PAF e T_{VIS} (Abertura Efetiva)

Para a verificação do efeito do agrupamento de duas variáveis-chave primárias (PAF e T_{VIS}) em uma secundária (Abertura Efetiva: $PAF * T_{VIS}$), verificaram-se as possíveis combinações de PAF e T_{VIS} . Para essas combinações, adotaram-se PAFs intervalados de 10% em 10% e T_{VIS} aproximadamente com o mesmo intervalo. Buscaram-se na biblioteca do EnergyPlus vidros com transmissão visível próxima a esses intervalos (ver Tabela 9). Os valores de Abertura Efetiva destacados em negrito nessa tabela foram os valores utilizados para compor os padrões de entrada das redes neurais. Os valores foram escolhidos de forma a compreender os valores mínimo e máximo (0,04 e 0,70) e um valor intermediário para a variável (0,37), visando ao processo de aprendizagem da rede e evitando a necessidade de extrapolação. Outros dois valores intermediários foram selecionados para compor o conjunto “nunca vistos” (0,18 e 0,53). Essas

combinações foram simuladas no EnergyPlus para as quatro orientações cardeais. Consequentemente, gerou-se uma arquitetura de rede composta de dois parâmetros de entrada – Orientação e Abertura Efetiva – e quatro de saída – Consumo Total, Consumo para Resfriamento, Aquecimento e Iluminação. Apesar de a adição do parâmetro Ventiladores como nó de saída (item 5.3.3) ter sido, em geral, positiva, optou-se por não utilizar essa saída, visto que não foi efetiva quanto ao desempenho do parâmetro iluminação.

Tabela 9 – Cruzamento dos valores de PAF e T_{VIS} e os Valores de Abertura Efetiva resultantes destacando-se os adotados deste trabalho


ABERTURA EFETIVA (adimensional)		PAF						
		0,20	0,30	0,40	0,50	0,60	0,70	0,80
T_{VIS}	0,22	0,04	0,07	0,09	0,11	0,13	0,15	0,18
	0,33	0,07	0,10	0,13	0,17	0,20	0,23	0,27
	0,45	0,09	0,14	0,18	0,23	0,27	0,32	0,36
	0,54	0,11	0,16	0,22	0,27	0,32	0,38	0,43
	0,74	0,15	0,22	0,30	0,37	0,44	0,52	0,59
	0,88	0,18	0,26	0,35	0,44	0,53	0,62	0,70

Fonte: Autor.

Os resultados dessas redes neurais foram comparados com os da rede EasyNN-plus, apresentada no item 5.3.2. Na Figura 30, essa rede é identificada por três entradas e a nova configuração de rede por duas entradas. Na Figura 30a, pode-se observar que, com exceção do resfriamento, todos os outros parâmetros de saída tiveram a precisão de suas previsões piorada para a nova configuração de rede.

Observando os erros separados por variável-chave (ver Figura 30b), a utilização da Abertura Efetiva melhorou a generalização da rede para Aquecimento e Resfriamento nos casos “nunca vistos” de Orientação, diminuindo o EPAM em cerca de 2,5% e 5%, respectivamente. Para Consumo Total e Iluminação, o EPAM aumentou em torno de 1%, mas, observando os erros de cada padrão do conjunto individualmente ($E_{\%absol}$), em alguns casos o erro diminuiu. Já quando comparados os casos “nunca vistos” de PAF e T_{VIS} com os de Aberturas Efetivas, o desempenho da segunda opção foi claramente pior, aumentando o EPAM de cerca de 2% para Iluminação a 30% para Aquecimento.

Figura 30 – Comparação entre redes neurais de mesma configuração para 3 e 2 parâmetros na camada de entrada



(a) separação por parâmetro de saída

(b) destacando as variáveis-chave do conjunto “nunca vistos”

Esses resultados indicam que variáveis-chave secundárias, provavelmente, precisem de mais exemplos de combinações das variáveis primárias na fase de treinamento, oferecendo mais subsídios para o aprendizado da rede.

Para esses testes, a variável PAF mostrou-se mais crítica que a T_{VIS} , visto que seus erros para o conjunto “nunca vistos” foram maiores, com exceção do Consumo com Iluminação, em que os dois foram equivalentes. Essa observação retrata a influência dessas variáveis nos fenômenos térmicos e luminosos inerentes a cada parâmetro de saída.

O critério de seleção dos dados para treinamento da rede mostrou-se aparentemente inadequado, visto que o parâmetro de saída Iluminação, que é mais diretamente afetado por essas variáveis, teve seu desempenho piorado. A adoção dos valores-limite e de um intermediário pareceu ser insuficiente para um parâmetro que representa duas variáveis. Uma consideração seria aumentar o número de combinações para que os padrões sejam mais bem assimilados pela rede.

5.3.3.3 Resultados da ação 3 – a adição de parâmetros de saída (suficiência da iluminação natural)

Os mesmos casos da ação anterior foram utilizados. Entretanto, duas configurações adicionais de rede foram propostas. A primeira, substituindo os parâmetros de saída referentes ao desempenho energético pelos dois parâmetros de saída de suficiência de iluminação (iluminância média e DA médio). Já a segunda, unindo os dois grupos,


totalizando seis parâmetros de saída, os quatro referentes ao desempenho energético e os dois ao luminoso. Optou-se por manter o parâmetro Abertura Efetiva como parâmetro de entrada para observar outras combinações de rede.

Na Figura 31, as barras azuis, legendadas por “2 parâmetros de entradas e 4 parâmetros de saídas”, referenciam-se à solução da ação anterior. As barras verdes, legendadas por “2 parâmetros de entradas e 2 parâmetros de saídas”, referem-se à solução com os parâmetros de iluminação. E as barras vermelhas correspondem à solução com todos os parâmetros de saída em uma mesma rede.

Comparando-se a solução de rede com todos os parâmetros de saída reunidos com a rede que tem apenas parâmetros de desempenho energético, observa-se uma leve piora geral no desempenho da rede, máximo de 3% para Aquecimento (ver Figura 31). Essa redução de desempenho de predição foi observada com mais intensidade para os casos nunca vistos de orientação para todos os parâmetros de saída.

Com relação aos parâmetros de iluminação, o EPAM também aumentou ao adotar a solução com todos os parâmetros de saída em uma só rede. Entretanto, a diferença entre as duas soluções é menos perceptível para $DA_{\text{médio}}$, sendo menor que 1%, enquanto para iluminância média é mais expressiva, cerca de 5%.

Figura 31 – Comparação entre as redes com parâmetros de saída energéticos, de iluminação e ambos



Quando avaliados os EPAMs separados por variável-chave do conjunto “nunca vistos”, a iluminância média apresentou piora no

desempenho tanto para os casos de Orientação nunca vista quanto para os casos de Abertura Efetiva nunca vista.

Com base nesses resultados, observou-se que parâmetros de saída de diferentes naturezas em uma mesma rede aumentam a complexidade do aprendizado e dificultam o ajuste dos pesos, de forma que tanto parâmetros de saída de energia quanto de iluminação apresentaram melhor desempenho quando considerados separadamente.

Apesar de os parâmetros de iluminação adotados não serem os mais indicados para a representação da suficiência de iluminação, a sua consideração nessa etapa do trabalho foi útil, possibilitando agilidade computacional na aquisição dos dados. Ambos foram considerados apropriados para a avaliação da natureza dos parâmetros; entretanto, devido a sua complexidade, serão abordados mais detalhadamente no Capítulo 7.

5.3.4 Alteração da arquitetura e parâmetros de treinamento da rede


De acordo com o item 5.2.4, as três ações realizadas neste conjunto foram:

- (1) avaliação dos critérios de parada do treinamento da rede;
- (2) testes com diferentes quantidades de camadas intermediárias; e
- (3) teste com o número de neurônios na camada intermediária.


5.3.4.1 Resultados da ação 1 – avaliação dos critérios de parada do treinamento da rede

Quanto ao critério de parada da rede, as opções *Quando o erro estiver abaixo de determinado alvo* e *Quando o erro estiver aumentando* apresentaram resultados muito semelhantes (ver Figura 32). Como o conjunto de validação foi avaliado a cada seis ciclos do treinamento, quer dizer que o erro começou a aumentar logo após ter atingido o erro-alvo dentro do mesmo conjunto de seis ciclos. Logo, nesse caso, os critérios não apresentaram diferença significativa; entretanto, nos casos em que o erro diminuiu sem atingir o erro-alvo e depois começa a aumentar, esses critérios podem resultar em redes com desempenho diferenciado.

Figura 32 – Desempenho das redes para diferentes critérios de parada – conjunto “nunca vistos”



(a) separação por parâmetro de saída



(b) separação por parâmetros de saída das redes

Quando analisados os erros dos parâmetros de saída individualmente, percebeu-se que não há uma relação entre o critério de parada e o desempenho de todos os parâmetros, visto que, dependendo do ciclo em que o treinamento foi parado, o erro de determinado parâmetro diminuía enquanto outro aumentava.


A rede parada em 100.000 épocas, conforme o treinamento descrito no item 5.3.2, foi a que apresentou pior desempenho para o conjunto validação, apesar de ter sido melhor para o conjunto de treino. O último teste, em que se observou o treinamento da rede de 100.000 épocas (ver gráfico da Figura 33) e interrompeu-se o treinamento no ciclo em que ocorria o menor erro do conjunto de validação, repassou essa melhora no desempenho para o conjunto “nunca vistos”. Entretanto, apresentou desempenho semelhante aos dos dois primeiros testes. Como é um processo mais trabalhoso e pode não ser aplicável, o aumento na demanda de tempo, no mínimo o dobro, não se justifica.

O número apropriado de ciclos varia, entre outros, com a complexidade da rede. Como o conjunto de dados utilizados é muito pequeno e a rede muito simples, as 100.000 épocas provavelmente deixaram que a rede fosse treinada em excesso, decorando os padrões e perdendo o poder de generalização. A Figura 33 mostra um exemplo dos erros mínimos, médios e máximos do conjunto de treinamento para três

primeiros dos quatro critérios de parada apresentados no Quadro 2, p. 155. Como se pode ver, os erros do treinamento para 100.000 épocas são muito inferiores que os demais, o que reforça a possibilidade de treinamento excessivo.

Figura 33 – Comparação do desempenho para os diferentes critérios de parada destacando-se graficamente o menor erro para o conjunto validação

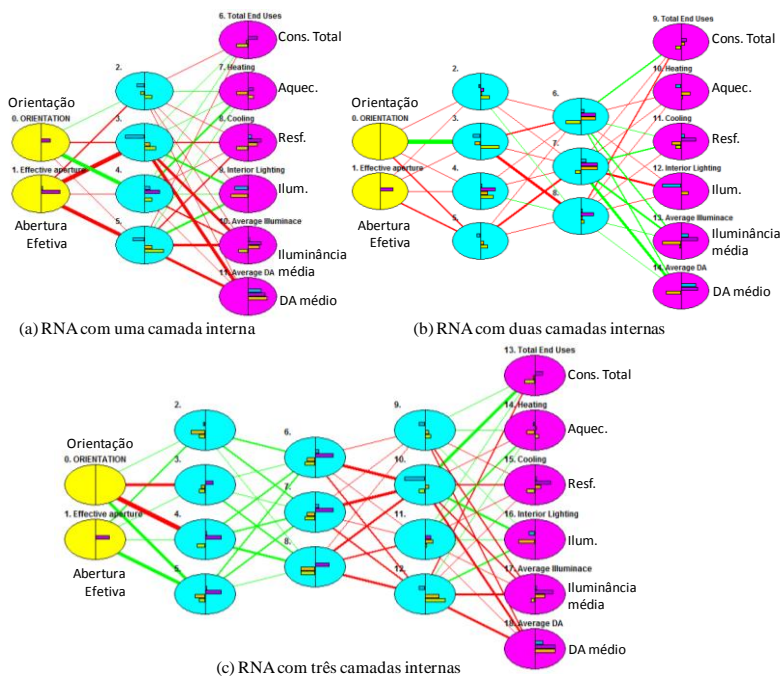
Critério de parada:	Critério de parada:	Critério de parada:
Número de ciclos, 100,000 ciclos (épocas)	O erro está abaixo no alvo X... 90 ciclos (épocas)	O erro está aumentando... Erro médio de validação 568 ciclos (épocas)
Erro máximo de teste: 0,00146720 Erro médio de teste: 0,00049644 Erro mínimo de teste: 0,00002006	Erro máximo de teste: 0,06152457 Erro médio de teste: 0,02346134 Erro mínimo de teste: 0,00214020	Erro máximo de teste: 0,05714997 Erro médio de teste: 0,00999621 Erro mínimo de teste: 0,00056637



5.3.4.2 Resultados da ação 2 – testes com diferentes quantidades de camadas intermediárias

As configurações das três redes testadas nesta ação são mostradas na Figura 34. Em amarelo destacam-se as camadas de entrada, em ciano as camadas intermediárias e em magenta as camadas de saída.


Figura 34 – Arquiteturas das três redes testadas



Fonte: Autor.

Comparando-se o desempenho das três soluções, aquela com apenas uma camada foi a que apresentou o melhor desempenho (ver Figura 35), com exceção do parâmetro de saída resfriamento, que apresentou menores erros para a solução com duas camadas. Essa verificação alinha-se com uma afirmação recorrente na bibliografia de que uma camada é suficiente e indicada para o redes PMC.

Figura 35 – Comparação entre as três arquiteturas de rede para cada padrão de saída

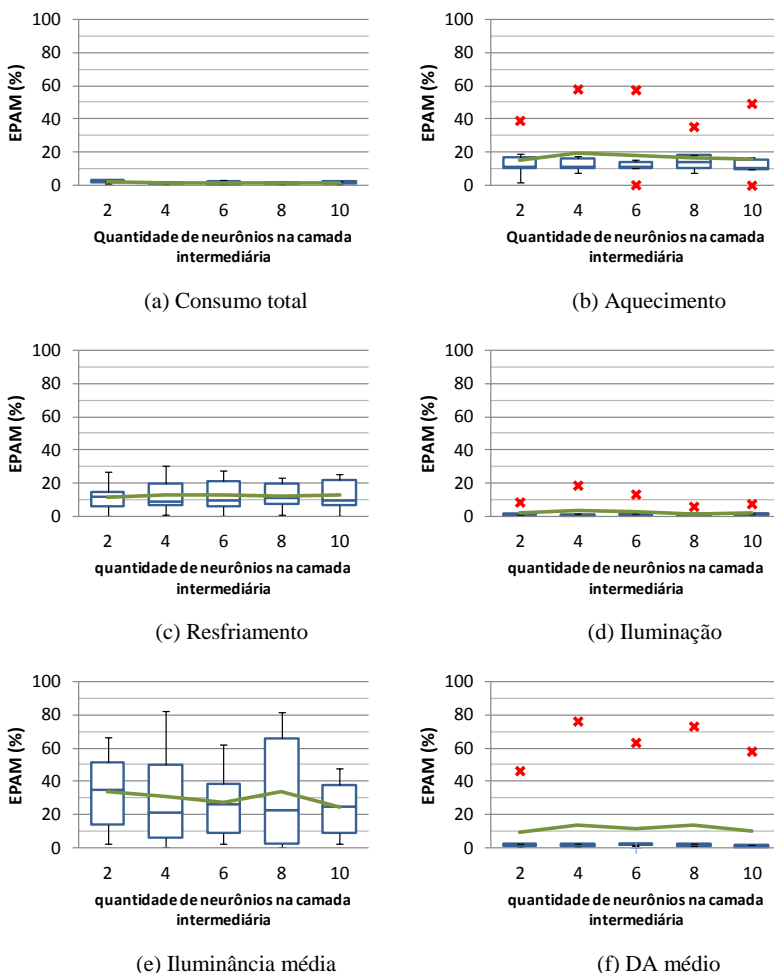


Outra observação é de que a alteração no número de camadas internas impactou mais na predição dos parâmetros de saída de iluminação que de consumo energético, o que pode sinalizar que parâmetros de saída de diferentes naturezas podem exigir arquiteturas de redes diferentes.

5.3.4.3 Resultados da ação 3 – teste com o número de neurônios na camada intermediária

Para a observação do efeito do número de neurônios no desempenho da rede, adotaram-se os diagramas de caixas a fim de encontrar algum padrão de ocorrência de erro para os diferentes parâmetros de saída (ver Figura 36). As primeiras observações mostraram que não houve nenhuma relação entre o número de neurônios e o desempenho dos parâmetros de saída de forma geral, visto que a melhor solução para um parâmetro de saída poderia ser a pior para outro.

Figura 36 – Comparação do efeito do número de neurônios no desempenho da rede através de diagramas de caixas



Identificando os valores discrepantes, sinalizados pelo “x” vermelho (ver Figura 36b, d, f), observa-se que o único discrepante inferior aconteceu para o Aquecimento, enquanto os discrepantes superiores ocorreram para Aquecimento, Iluminação e $DA_{\text{médio}}$. O discrepante inferior significa que a rede neural praticamente acertou a previsão desse valor (EPAM próximo a zero); entretanto, essa previsão


não condiz com a tendência do grupo, que apresentou EPAMs mais altos. Apesar de a dispersão desse grupo ter sido pequena, visto que os “bigodes” da caixa são pequenos, esse valor discrepante poderia direcionar o valor da média para um valor muito mais baixo e, com isso, causar ruído na observação do real comportamento do grupo.

Os diagramas de caixas permitiram observar que o parâmetro $DA_{\text{médio}}$, que em uma avaliação prévia mostrava média de erros elevados, na verdade apresenta erros baixos, mascarados pelo discrepante superior. Mesmo observando os gráficos de aquecimento, iluminação e $DA_{\text{médio}}$ sem os discrepantes, não foi possível definir um padrão para um número de neurônios que fosse aplicável a todos os parâmetros de saída.

O discrepante superior refere-se a um modelo orientado a Norte com Abertura Efetiva 0,18. É importante destacar que essa abertura efetiva resulta da combinação entre PAF 80% e T_{VIS} 22%, ou seja, o maior PAF e a menor T_{VIS} . Mesmo que o valor da Abertura Efetiva esteja dentro dos limites dos padrões de treinamento, a rede tem que ser mais robusta, com mais padrões de treinamento, para representar os efeitos de diferentes combinações que gerem a mesma abertura efetiva.

Observando o gráfico geral das redes (ver Figura 37), a arquitetura com 10 neurônios foi a que apresentou a menor dispersão e os menores erros, seguida da rede com seis neurônios e da rede com dois neurônios. A rede com oito neurônios foi a que apresentou a maior dispersão; entretanto, observando os gráficos da Figura 36, pode-se verificar que essa dispersão deve-se ao parâmetro Iluminância média e não retrata a tendência dos outros parâmetros de saída.

Figura 37 – Identificação dos modelos referentes aos valores discrepantes – EPAM global das redes



A ferramenta de definição do número de neurônios do programa EasyNN-plus determinou quatro neurônios ocultos para essa tipologia

de rede neural. A observação desses resultados mostra que a ferramenta não necessariamente leva a uma boa ou a uma melhor configuração de neurônios na camada interna. Como nenhum padrão foi encontrado, entendeu-se que a ferramenta pode ser adotada, mas apenas como um direcionador para a definição do número de neurônios. A partir da resposta da ferramenta, novos testes devem ser realizados em busca da configuração de rede desejada.

5.3.5 Investigação da variável Orientação

Como descrito no item 5.2.5, para este grupo adotaram-se três ações:

- (1) análise da codificação de entrada de orientação para a RNA;
- (2) análise da influência do aumento de padrões no conjunto de treinamento; e
- (3) análise dos efeitos do parâmetro Orientação com relação às outras variáveis-chave.


5.3.5.1 Resultados da ação 1 – análise da codificação de entrada de orientação

Para os testes da variável Orientação, retomou-se a configuração de rede neural com os parâmetros PAF e T_{VIS} apresentados individualmente à rede. Como parâmetros de saída, limitaram-se aos parâmetros de energia. Logo, a arquitetura da rede foi a mesma do item 5.2.2, com três nós na camada de entrada e quatro na camada de saída. Manteve-se o uso da ferramenta do EasyNN-plus para a escolha do número de neurônios na camada oculta. Para as combinações paramétricas do conjunto de treinamento, as variáveis foram as quatro orientações cardeais (N, S, L, O); o PAF (20%, 50% e 80%) e a T_{VIS} (25%, 57% e 91%). Para o conjunto “nunca vistos”, os três valores de PAF e T_{VIS} foram combinados com as orientações colaterais e subcolaterais e com os azimutes 15° , 145° , 260° e 320° .

Foram analisados os erros para cada uma das 10 redes neurais, agrupados conforme a combinação entre PAF e T_{VIS} para as 17 orientações. A Figura 38 ilustra a combinação T_{VIS} 0,57 e PAF 20% para o parâmetro Consumo Total. As demais combinações estão disponíveis no APÊNDICE C , p.425. Os gráficos foram plotados em escala polar para uma melhor visualização em quais orientações ocorriam os maiores erros. Os erros são marcados no raio dos gráficos. Essa análise confirmou a importância de se treinarem 10 redes neurais


para fazer observações sobre tendências das RNAs, visto que a distribuição dos erros para orientação é bastante diversa. Apesar disso, foi possível definir padrões levando em conta que alguns pontos extremos podem ser considerados pontos discrepantes e não representativos da média.

Figura 38 – Comparação entre o desempenho de cada uma das 10 RNAs para cada orientação para a combinação T_{VIS} 0,57 e PAF 20% (parâmetro de saída: Consumo Total - EPAM)




Para a comparação das três abordagens de codificações testadas, foram analisados gráficos derivados do apresentado na Figura 38, em que o agrupamento foi refeito para cada combinação de PAF e T_{VIS} e cada linha, agora, corresponde à média das 10 RNAs. A Figura 39 ilustra os gráficos dos EPAMs para o parâmetro de saída Consumo Total. Essa análise foi feita para os quatro parâmetros de saída, estando os demais gráficos apresentados no APÊNDICE C , p. 425. Os pontos destacados com círculos hachurados correspondem aos casos do conjunto validação. A combinação de PAF e T_{VIS} destacada em vermelho na legenda da Figura 39 corresponde à média das redes apresentadas na Figura 38.

Figura 39 – Comparação entre o desempenho da média das 10 RNAs para cada caso: agrupamento por combinação PAF e T_{VIS} para as três codificações (parâmetro de saída: Consumo Total)



Legenda:



As análises mostraram que, em geral, os erros aumentaram para a codificação cíclica em relação à codificação cardeal. A limitação da abordagem cíclica, descrita no item 5.2.5, p. 156, pode ser verificada no gráfico da Figura 39b, visto que a rede apresentou erros inferiores a 5% para modelos com a fachada orientada à Leste (metade direita do gráfico) e, ao não diferenciar os efeitos térmicos das fachadas Leste e Oeste, estendeu as previsões de uma fachada para a outra, consequentemente, prejudicando as previsões dos casos “fachada Oeste”, com EPAM de até 8% (metade esquerda do gráfico). Os casos da orientação Oeste que apresentaram erro próximo a zero referem-se à orientação Oeste propriamente dita (270°) e ocorreram pelo fato de fazerem parte do conjunto de treinamento.

A adição da orientação 359° N para a codificação das orientações melhorou significativamente o desempenho das previsões da rede para orientações do quadrante NE. A média do EPAM para todos os casos com orientações pertencentes a esse quadrante, para Consumo Total, Aquecimento e Iluminação, foi reduzida à metade.

5.3.5.2 Resultados da ação 2 – análise da influência do aumento de padrões no conjunto de treinamento

A análise referente ao acréscimo da quantidade de padrões no treinamento manteve a observação de gráficos polares complementada por diagrama de caixas. Os primeiros permitiram observar a redução dos

erros nos quadrantes Norte, em especial para Resfriamento e Iluminação, tendo o EPAM para resfriamento, que apresentava valores máximos em torno de 10%, reduzido para 6% e para Iluminação, que apresentava valores máximos em torno de 20%, reduzido para 13%. Entretanto, a média de todos os pontos desses quadrantes variou de 3,3% para 2,9% para Resfriamento e de 4,7% para 4,2% para Iluminação, indicando dispersão dos dados.

As características dos gráficos da Figura 40 e da Figura 41 mostram os resultados de EPAM para os três conjuntos de treinamento: orientações cardeais + 359° N (5 orientações), cardeais + 359° N + colaterais (9 orientações) e cardeais + 359° N + colaterais + subcolaterais (17 orientações). A Figura 40 ilustra os erros do treinamento propriamente dito; e a Figura 41, o conjunto “nunca vistos”. O conjunto corresponde aos azimutes 15°, 145°, 260° e 320°, combinados com os três valores de PAF e os três de T_{VIS}.

Figura 40 – Comparação dos efeitos do aumento da quantidade de padrões no treinamento: resultado do conjunto de treinamento





Figura 41 – Comparação dos efeitos do aumento da quantidade de padrões no treinamento: resultado do conjunto “nunca vistos”



Observando os dois gráficos, em especial o do conjunto “nunca vistos” (ver Figura 41), pode-se perceber uma redução dos erros, em especial para o parâmetro de saída de resfriamento, quando foram consideradas nove orientações no conjunto de treinamento. As tendências do parâmetro aquecimento foram desconsideradas por serem ruidosas devido aos seus valores absolutos extremamente baixos. O aumento para 17 orientações não apresentou melhora clara nos resultados das predições para o conjunto de treinamento nem para o conjunto “nunca vistos”. Sendo assim, o esforço computacional para realizar as simulações energéticas para essas orientações pode não se justificar.

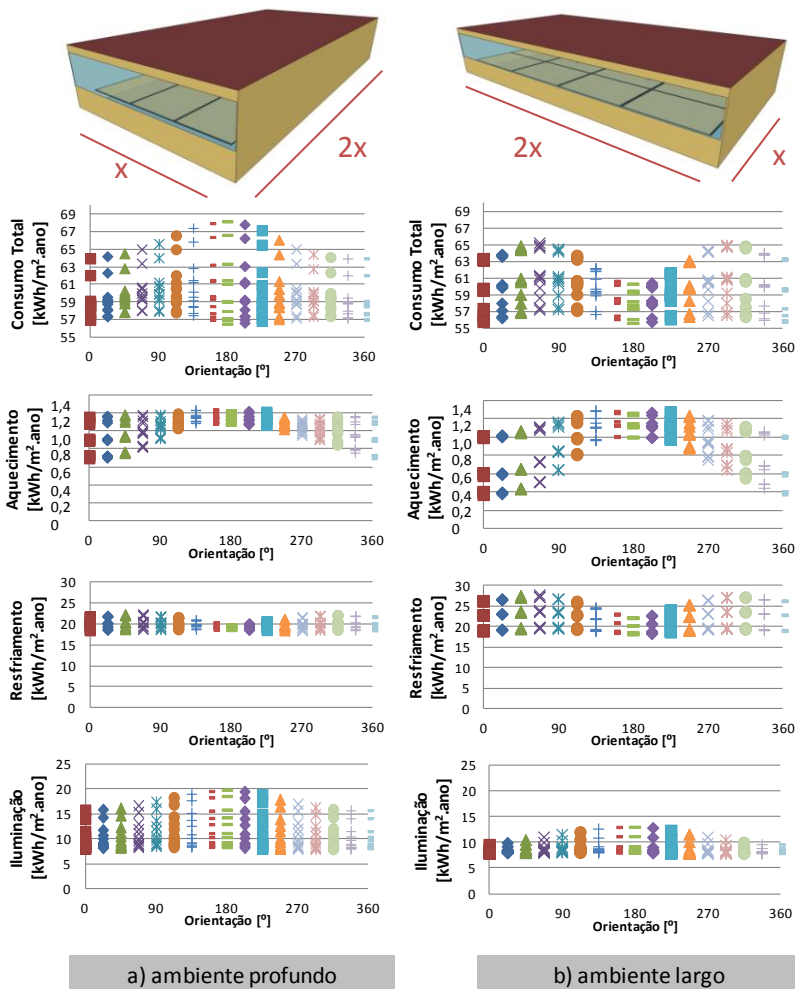
5.3.5.3 Resultados da ação 3 – análise dos efeitos do parâmetro Orientação com relação às outras variáveis-chave

Inicialmente, os resultados das simulações das duas geometrias (ambiente largo – “2 x 1” e ambiente profundo – “1 x 2”) no EnergyPlus foram plotados em gráficos de pontos e, em um segundo momento, em gráficos de bolhas, procurando identificar especificidades que merecessem atenção ao definir os conjuntos de treinamento das RNAs. Nesse caso, foram plotados os resultados apenas das orientações principais (N, S, L e O) em gráficos de bolhas.


Observando a Figura 42, pode-se notar a complexidade inserida no problema quando se acrescenta a variável Geometria relacionada à Orientação para ser modelada. No caso, ambos os modelos possuem a mesma área, volume e plano iluminante e foram comparados os mesmos PAFs. A diferença no padrão das curvas tanto de Consumo Total quanto de Aquecimento, Resfriamento e Iluminação se apresenta como um potencial desafio ao apresentar diferentes geometrias com diferentes orientações para as RNAs.

Outra constatação é de que a dispersão entre os resultados para cada Orientação ocorre principalmente para a Iluminação, seguida do Resfriamento. Chama-se atenção para a diferença no comportamento dos dados, principalmente, para a fachada Sul. Nesse caso, pode-se supor que as RNAs apresentam maiores erros na generalização para essa fachada quando as duas geometrias forem abordadas em uma mesma rede.

Figura 42– Comparação entre o consumo de duas geometrias: ambiente profundo e ambiente largo, para as 17 orientações separado por uso final



Legenda das Orientações:




Quanto menos linear e mais complexo o fenômeno, maior é a complexidade da rede neural. Da Figura 43 à Figura 46 o fenômeno é avaliado através dos gráficos bolha, como explanado na Figura 26,


p.158, sendo neste caso a orientação, a variável 1 (cor, abscissas); T_{VIS} a variável 2 (tom); e o PAF a variável 3 (tamanho). Quanto mais escuro o tom da cor, maior a T_{VIS} ; e quanto maior a bolha, maior o PAF. A Figura 43 apresenta os resultados de consumo para Consumo Total, a Figura 44 para Aquecimento, a Figura 45 para Resfriamento e a Figura 46 para Iluminação.

Observando os gráficos de bolhas da Figura 43a referentes ao Consumo Total, verifica-se que no ambiente de geometria profunda os modelos com menores PAFs e T_{VIS} apresentam o maior consumo energético. Entretanto, os maiores PAFs e T_{VIS} não necessariamente correspondem ao menor consumo. Para as quatro orientações, os menores consumos ocorrem para valores intermediários de PAF e T_{VIS} . Para a geometria larga, Figura 43b, quanto maiores PAF e T_{VIS} , maior é o consumo. O menor consumo ocorre para os menores PAFs e as maiores T_{VIS} . Para a orientação sul, esse padrão não é muito claro, o que pode dificultar o aprendizado das RNAs.

Figura 43 – Visualização do padrão de Consumo Energético Total em função da Orientação, T_{VIS} e PAF




Legenda:




A primeira observação quanto aos resultados apresentados na Figura 44 é de que os baixos valores de consumo para Aquecimento podem levar a maiores erros para as RNAs. Quanto à geometria profunda ilustrada na Figura 44a, a diferença de padrão de distribuição, a dispersão dos valores para a orientação norte e a sobreposição nas fachadas sul e oeste podem exigir maior esforço para o aprendizado da

RNA. Para a geometria larga (ver Figura 44b), a orientação norte com menores valores de consumo e maior amplitude pode também dificultar o aprendizado das RNAs. Esse padrão pode se estender às fachadas nordeste e noroeste.

Figura 44 – Visualização do padrão de Consumo de energia para Aquecimento em função da Orientação, T_{VIS} e PAF




Legenda:




O ponto a ser salientado como possível dificultador do aprendizado das RNAs, no caso do Resfriamento para a geometria profunda, é a sobreposição dos diferentes casos para a orientação sul (ver Figura 45a). Já para a geometria larga, dois pontos que podem complicar o aprendizado são observados na Figura 45b: o primeiro pelo fato de a orientação sul apresentar valores significativamente inferiores às demais orientações e com menor dispersão; e o segundo pelo fato de que, para as quatro orientações, quando PAF é 20%, o consumo para modelos com T_{VIS} 0,88 é menor que para T_{VIS} 0,43, em oposição ao que acontece com os outros PAFs (50% e 80%).

Figura 45 – Visualização do padrão de Consumo de energia para Resfriamento em função da Orientação, T_{VIS} e PAF




Legenda:




Como pode ser observado na Figura 46, ambas as geometrias apresentam maior dispersão para a orientação sul, sendo essa a que mais difere das outras orientações em termos de dispersão. Isso ocorre porque a orientação sul é a que menos recebe insolação, ficando mais dependente do sistema de captação de luz (janela: PAF e T_{VIS}), bem como da geometria que irá distribuir a luz captada. Nos dois gráficos da Figura 46 pode-se perceber que os modelos com os maiores PAF e T_{VIS} apresentam os menores consumos, ao passo que os com menores PAF e T_{VIS} apresentam os maiores consumos. O ambiente de geometria profunda é mais sensível à influência da janela, pois apresenta uma relação de área bruta de janela por área do ambiente menor, recebendo menos luz que o de geometria larga. Para o ambiente de geometria larga, existe a sobreposição de casos, em especial para a orientação norte, pois, nesse caso, o ambiente recebe mais luz e com melhor distribuição, ficando menos dependente das variações do sistema de captação de luz. Para as duas geometrias, a maior sobreposição de bolhas ocorre para PAF 50% e 80%; nesses casos, a combinação de PAF e T_{VIS} não permite que nenhum dos dois acompanhe ordenadamente (linearmente) a escala de Consumo. Esse efeito, combinado com o padrão diferente de dispersão das geometrias, pode se tornar um gargalo do aprendizado da rede.

Figura 46 – Visualização do padrão de Consumo de energia para Iluminação em função da Orientação, T_{VIS} e PAF



Legenda:



Esses mesmos gráficos também foram plotados com PAF e T_{VIS} no eixo das abscissas e utilizados como base para o grupo de ações seguinte.

5.3.6 Investigação das variáveis PAF e T_{VIS}

De acordo com o item 5.2.6, para este grupo adotaram-se duas ações:

- (1) análise da influência do aumento de padrões no conjunto de treinamento para PAF e T_{VIS} ; e
- (2) análise da influência do aumento de padrões direcionados à ocorrência dos maiores erros.

5.3.6.1 Resultados da ação 1 – análise da influência do aumento de padrões no conjunto de treinamento para PAF e T_{VIS}

A solução “cardeais+359°N” para Orientação foi combinada com sete valores para PAF e sete para T_{VIS} . A Figura 47 ilustra a forma como esses valores foram inseridos no conjunto de treinamento para PAF e T_{VIS} , respectivamente.

Figura 47 – Descrição das etapas de inclusão de padrões no conjunto de treinamento

Análise de PAF

Caso Base – conjunto mínimo

Valores do conjunto de treinamento
(20% para o conjunto validação)

ORIENTAÇÃO	PAF	T_{vis}
LESTE (90°)	20%	25%
NORTE (0°)	80%	57%
SUL (180°)		91%
OESTE (270°)		
NORTE (359°)		

Conjunto “nunca vistos” (NV)

NV 1 _{PAF}	NV 2 _{PAF}	NV 3 _{PAF}
50%	35%	40%
	65%	70%

CASO A:
CASO BASE
+ NV1

CASO B:
CASO BASE
+ NV1 + NV2

Análise de T_{vis}

Caso Base – conjunto mínimo

Valores do conjunto de treinamento
(20% para o conjunto validação)

ORIENTAÇÃO	PAF	T_{vis}
LESTE (90°)	20%	25%
NORTE (0°)	50%	91%
SUL (180°)	80%	
OESTE (270°)		
NORTE (359°)		

Conjunto “nunca vistos” (NV)

NV 1 _{T_{vis}}	NV 2 _{T_{vis}}	NV 3 _{T_{vis}}
57%	45%	54%
	74%	88%

CASO A:
CASO BASE
+ NV1

CASO B:
CASO BASE
+ NV1 + NV2

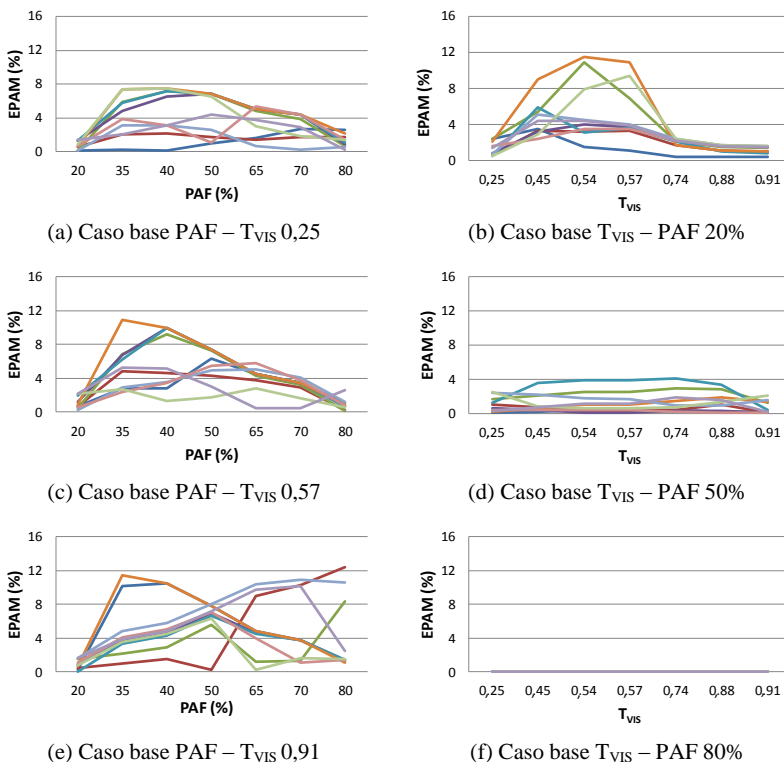
A análise dos resultados de ambas as variáveis se deu através da mesma abordagem da avaliação da orientação no conjunto de ações anterior: análise dos erros de cada RNA individualmente, análise dos erros médios e dispersões das 10 RNAs por parâmetro de saída (em vez de diagramas de caixas, utilizaram-se gráficos de barras), gráficos de pontos diferenciando-se o conjunto em que o dado se encontra (treinamento/validação/teste) e gráficos de bolhas.

Quanto à avaliação individual das 10 RNAs, a variabilidade do desempenho das diferentes redes, já observado no item anterior através do EPAM (ver Figura 38, p.180) foi confirmada (ver Figura 48). Entretanto, pode-se observar que essa variabilidade é suavizada quando o fenômeno é menos complexo, como, por exemplo, para a geometria larga, quando o PAF é expressivo (50% e 80%), a variação de T_{vis} é menos impactante no consumo, visto que essa geometria apresenta o dobro de área de fachada em relação à profundidade. Assim, o efeito da combinação dessas variáveis no fenômeno físico é simplificado e, portanto, mais facilmente interpretado pelas redes. A título de ilustração, a Figura 48 mostra os gráficos para os casos-base, para o parâmetro de

saída Consumo Total e para a orientação Oeste, agrupados conforme PAF e T_{VIS} . Os gráficos para as demais orientações foram disponibilizados no APÊNDICE D p.431. Os gráficos dos casos-base T_{VIS} (Figura 48b) ilustram bem a afirmação supracitada, pois, conforme o PAF aumenta, as variações de desempenho entre as 10 redes diminuem. A principal diferença entre os exemplos dos casos-base PAF (Figura 48a) e os dos casos-base T_{VIS} (Figura 48b) é de que, no primeiro, se analisam EPAMs de redes que abordam combinações de 7 PAFs com 3 T_{VIS} , enquanto, no segundo, as combinações são de 7 T_{VIS} com 3 PAFs.

Essa tendência de comportamento pode ser observada para as quatro orientações (ver APÊNDICE D p.431), com exceção da orientação Oeste- T_{VIS} 0,91 (Figura 48a) e Norte- T_{VIS} 0,25, para as quais aproximadamente metade das redes apresentou comportamentos distintos.

Figura 48 – Comparação entre o desempenho de uma das 10 RNAs: agrupamento por orientação Oeste e variável a ser observada (PAF ou T_{VIS}) (parâmetro de saída: Consumo Total)



Análise PAF (Oeste)

Análise T_{VIS} (Oeste)

Legenda:



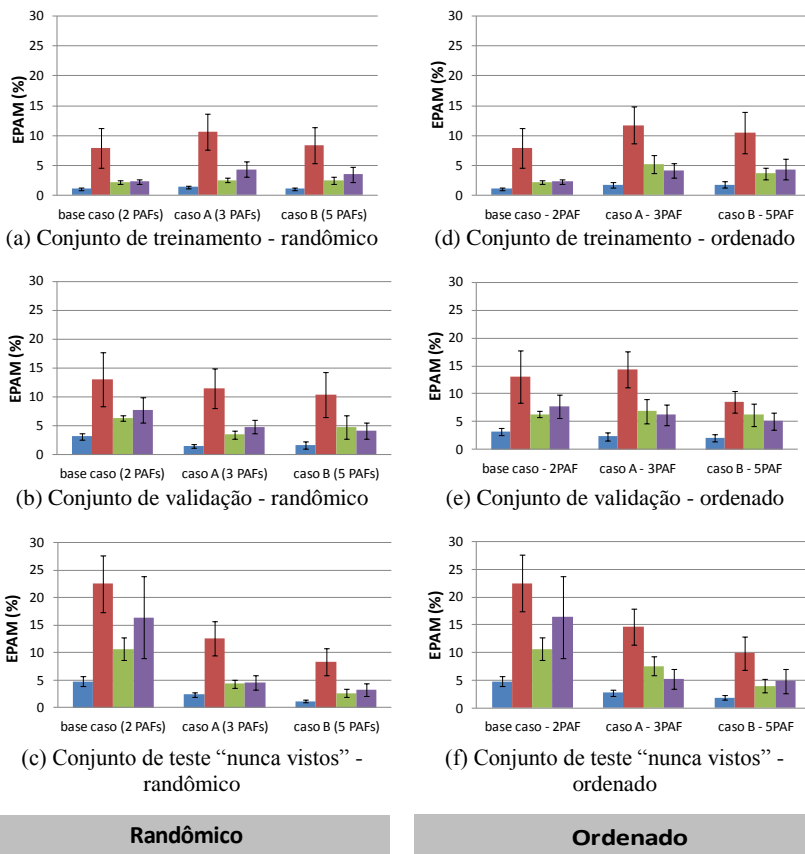
A Figura 49 ilustra os resultados da inclusão de novos padrões na fase de treinamento para PAF, segundo a sequência mostrada na Figura 47, p.189. Nesses gráficos, as barras representam o EPAM (considerando as 10 RNAs) para cada padrão de saída e os “bigodes” representam o desvio padrão do conjunto. Os dados foram apresentados às redes de duas formas: randômica apresentada na Figura 49a, b e c; e

ordenada na Figura 49d, e e f. O método randômico, em geral, apresentou melhor desempenho para os três conjuntos (treino/validação/“nunca vistos”), visto que reduziu o erro percentual médio, embora não tenha melhorado o desvio padrão.

Para o conjunto de treinamento (ver Figura 49a), o caso-base foi o que apresentou menores erros para os quatro padrões de saída, seguido do caso B e depois do caso A. O conjunto validação (ver Figura 49b) não possibilitou a observação de um padrão de erro comum aos quatro parâmetros de saída.

Para o conjunto “nunca vistos” (ver Figura 49c), a inclusão de parâmetros do caso-base para o caso A e para o caso B melhorou o desempenho da rede para os quatro parâmetros de saída. A maior diferença entre os casos ocorreu do caso-base para o caso A (inclusão de um padrão intermediário), indicando que uma função que possivelmente representaria a relação do aumento do número de padrões com a precisão da rede para os casos desse estudo seria uma função parabólica com tendência linear à direita (as linhas de tendência podem ser observadas na Figura 63, p. 212). Para estender essa suposição a outros casos, as configurações da RNA devem ser avaliadas, visto que o aumento excessivo de exemplos no treinamento pode levar ao superajuste, piorando as previsões da rede e fazendo com que a tendência linear passe a ser ascendente. Os traçados destas funções serão discutidos no item 6.4.

Figura 49 – Efeito da inclusão de novos casos de PAF no treinamento da rede considerando o consumo dos quatro usos finais.



Legenda:


■ Cons. Total ■ Aquec. ■ Resfr. ■ Ilum.

A avaliação da variável-chave T_{VIS} foi realizada nos mesmos moldes da de PAF. Em geral, os erros do conjunto de treinamento (ver Figura 50a) variaram muito pouco com a inclusão dos novos padrões (menos de 1% em termos absolutos), com exceção dos erros de aquecimento, mas estes erros não foram considerados relevantes devido aos baixos valores absolutos de consumo por aquecimento. Mesmo assim, os menores erros correspondem ao caso-base. Já o conjunto

validação (ver Figura 50b), apesar de também não apresentar variação significativa de EPAM nem de desvio padrão, em geral apresentou melhora no desempenho dos parâmetros de saída conforme a adição dos novos padrões.

Para o conjunto “nunca vistos”, diferentemente de PAF, a função que poderia relacionar o desempenho da rede com o número de exemplos de variações de padrões não é clara. Considerando o conjunto apresentado à rede de forma randômica, ilustrado na Figura 50c, para Iluminação e Resfriamento, o desempenho melhorou do caso-base para o caso A, mas piorou do caso A para o caso B. Os erros do caso B foram menores que do caso-base e a diferença de desempenho entre um caso e outro foi maior entre o caso-base e o caso A. Consumo total e Aquecimento apresentaram redução nos erros do caso-base para o caso A e deste para o caso B. Quando da apresentação dos dados para a rede foi feita de forma ordenada, o mesmo padrão de Iluminação e Resfriamento para os randômicos pode ser observado para os quatro padrões de saída. Logo, a função para T_{VIS} poderia ser similar à de PAF, mas com a parábola menos acentuada, ou poderia ser uma parábola que, em vez de apresentar tendência linear à direita, apresentasse uma leve tendência a subir novamente (as linhas de tendência podem ser observadas na Figura 63, p. 212).

Figura 50 – Efeito da inclusão de novos casos de T_{VIS} no treinamento da rede considerando o consumo dos quatro usos finais.



Legenda:


■ Cons. Total ■ Aquec. ■ Resfr. ■ Ilum.

Comparando-se os resultados de Orientação (ver Figura 41, p.182), PAF (ver Figura 49c, p.193) e T_{VIS} (ver Figura 50c), pode-se considerar que as funções para orientação e T_{VIS} são mais parecidas entre si. PAF foi a variável que se mostrou mais influenciada pela adição de novos exemplos à RNA, considerando-se parâmetros de saída relacionados ao consumo.

A observação dos erros separados por conjunto (treino/validação/teste e “nunca vistos”) permitiu verificar de que forma, ao transferir um padrão para o conjunto de treinamento, a rede aprenderia e generalizaria melhor. Na Figura 51 foram destacados os EPAMs para o parâmetro de saída Iluminação para as redes baseadas em PAFs. Cada ponto do gráfico é resultante do erro médio das 10 RNAs. Em paralelo, foram analisados os mesmos gráficos, mas do tipo bolha, na mesma abordagem apresentada anteriormente. A observação desses gráficos para todos os parâmetros de saída, considerando os casos ordenados e randômicos, mostrou que


- PAFs menores (35% e 40%) resultaram em maiores erros para Iluminação e, na maioria dos casos, também para Resfriamento e Consumo Total, enquanto PAFs maiores (65% e 70%) levaram a maiores erros de Aquecimento. No primeiro caso, a justificativa é a mesma apresentada na avaliação das redes individualmente (ver Figura 48): os efeitos decorrentes da relação entre PAF e T_{VIS} são mais complexos de se modelar para valores menores, em que a importância de ambas as variáveis é mais equilibrada. Justamente esse balanço afeta em primeiro lugar a iluminação e depois o condicionamento de ar. No caso do aquecimento, como o erro foi avaliado em termos percentuais, quanto menor o valor do consumo, mais sensível é o EPAM em relação ao erro absoluto (EAM); e
- o mesmo pode ser observado para T_{VIS} , em que os menores valores (45%, 54% e 57%) levaram aos maiores erros para Iluminação e, na maioria dos casos, para Resfriamento e Consumo Total.

Figura 51 – Adição de padrões ao conjunto de treinamento para PAF, avaliado segundo EPAM do parâmetro Consumo de Iluminação




*NV = Conjunto "nunca vistos"
Em outra escala.

(a) Caso-base (2 PAFs)



*NV = Conjunto "nunca vistos"
(b) Caso A (3 PAFs)



*NV = Conjunto "nunca vistos"
(c) Caso B (5 PAFs)


Esse tipo de análise permitiu observar onde ocorriam os maiores erros, dando origem à ação (2).

5.3.6.2 Resultados da ação 2 – análise da influência do aumento de padrões direcionados à ocorrência dos maiores erros

De acordo com a etapa anterior, escolheu-se o parâmetro de saída Iluminação para verificar se o aumento de padrões com valores próximos aos padrões nos quais ocorreram os maiores erros poderia melhorar o modelo. Através dos gráficos da Figura 52a e b e da Figura 53a e b, observaram-se os casos em que esses erros ocorreram. Simularam-se novos casos paramétricos considerando PAF 30% e 45% e T_{VIS} 33% e 50%. Esses casos foram incluídos no treinamento, novas redes neurais foram geradas e efeitos nos conjuntos “nunca vistos” foram avaliados novamente. Essa etapa será chamada de caso C.

Na Figura 52b, para a avaliação das bolhas (ver Figura 26, p.158) o PAF, a variável 1 (abscissas); e na Figura 53b, T_{VIS} é a variável e (abscissas).


Figura 52 – Identificação da ocorrência dos maiores erros para PAF – parâmetro de saída iluminação



(a) EPAM para caso base, casos A e B - conjunto “nunca vistos” por uso final

(b) EPAM para caso base – parâmetro de saída iluminação

Figura 53 – Identificação da ocorrência dos maiores erros para T_{VIS} – parâmetro de saída iluminação

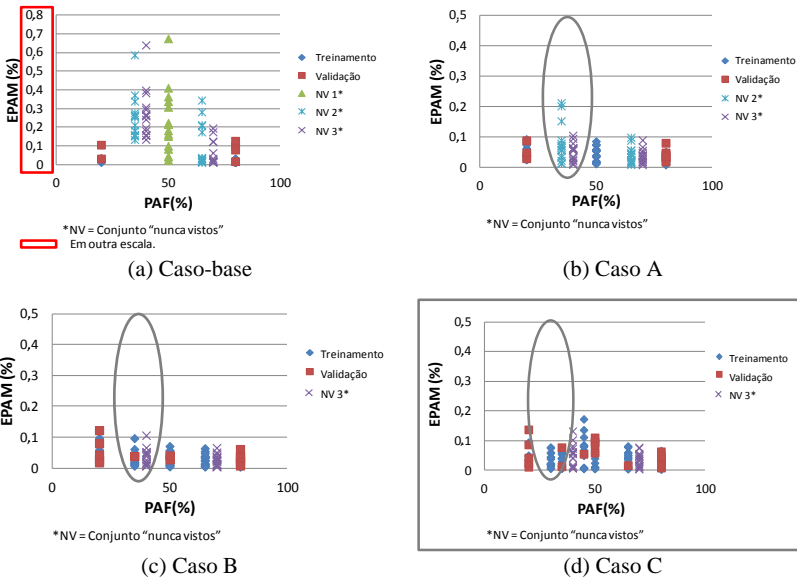


(c) EPAM para caso base, casos A e B - conjunto “nunca vistos” por uso final

(d) EPAM para caso base – parâmetro de saída iluminação

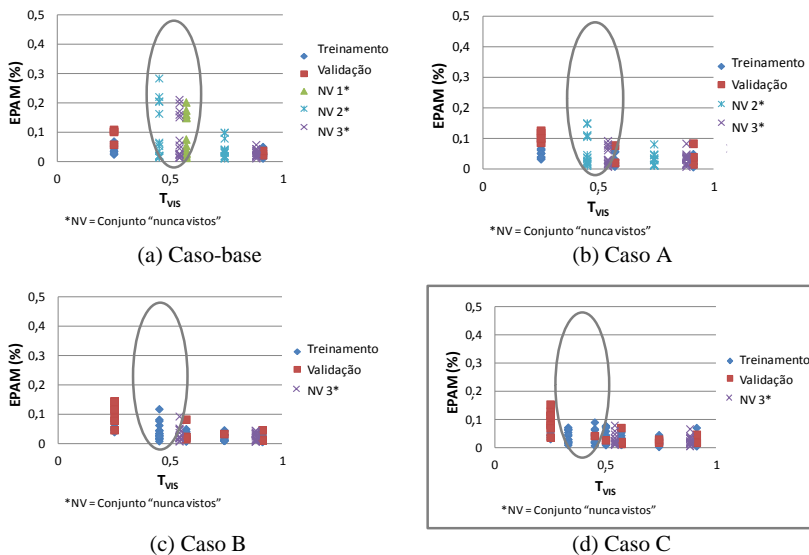
A observação dos resultados referiu-se aos conjuntos ordenados e randômicos para os quatro padrões de saída. Os gráficos resultantes da inclusão dos novos padrões foram destacados com um quadro cinza na Figura 54 e na Figura 55. A Figura 54 ilustra o efeito da inclusão dos novos padrões para PAF para o parâmetro de saída iluminação, apresentados randomicamente às redes. Nesse caso, a inclusão dos novos padrões no treinamento melhorou a predição das redes para os casos do conjunto “nunca vistos” para todos os parâmetros de saída, com exceção da iluminação para o caso randômico, como pode ser observado no exemplo da Figura 54d.

Figura 54 – Efeito da inclusão dos novos padrões para PAF – parâmetro de saída iluminação



A Figura 55c ilustra o efeito da inclusão dos novos padrões para T_{VIS} para o parâmetro de saída iluminação, apresentados randomicamente às redes. Em geral, a inclusão dos novos padrões no treinamento também melhorou a predição das redes para os casos do conjunto “nunca vistos”, com exceção dos parâmetros Consumo total para ordenados e Aquecimento para randômicos, para os quais não se observou melhora.

Figura 55 – Efeito da inclusão dos novos padrões para T_{VIS} – parâmetro de saída iluminação



Tanto para PAF quanto para T_{VIS} , a adição de novos padrões para aumentar a quantidade de exemplos nos pontos em que os erros da rede são maiores não resultou, necessariamente, em melhora no desempenho do modelo, embora na maioria dos casos isso tenha ocorrido.

Com base em todas as análises (Figura 54 e Figura 55), além dos gráficos dos outros parâmetros de saída não apresentados aqui, tanto para PAF quanto para T_{VIS} pode-se observar que, apesar de a escolha dos novos padrões ter sido feita baseada nos erros do parâmetro iluminação, os outros parâmetros foram beneficiados, mesmo nos casos em que a própria predição de iluminação piorou. Em alguns casos, os maiores erros dos outros parâmetros de saída ocorreram inclusive na outra extremidade do gráfico (valores altos de PAF e T_{VIS}), o que demonstra que mesmo dados de entrada paramétricos não precisam necessariamente ser homogeneamente distribuídos para que o metamodelo possa generalizar. Por outro lado, a melhora no modelo não foi tão significativa a ponto de justificar a geração de mais modelos para serem simulados (simulação energética).

5.3.7 Refinamentos dos tópicos anteriores

Seguindo a descrição do item 5.2.7, para este grupo, adotaram-se quatro ações:

- (1) inclusão do parâmetro fator solar (FS) como parâmetro de entrada da RNA para a descrição do vidro;
- (2) isolamento de cada um dos parâmetros de saída em redes individuais;
- (3) proposição de redes neurais individuais para cada orientação; e
- (4) refinamento do número de neurônios na camada interna e do algoritmo de otimização.

5.3.7.1 Resultados da ação 1 – inclusão do parâmetro fator solar (FS)

Com base nos conjuntos de PAF e T_{VIS} do conjunto de ações anterior (ver item 5.3.6), acrescentou-se o Fator Solar como parâmetro de entrada da rede. Os vidros escolhidos foram mantidos. Mantendo-se a abordagem de testes com redes diferentes para PAF e T_{VIS} , procurou-se observar a relação da inclusão desse parâmetro de entrada, que complementa a descrição do vidro, para casos nunca vistos, enfocando novas aberturas (PAFs) e novos tipos de vidro (T_{VIS}). Para esse fim, os resultados dessa ação foram comparados com os resultados dos casos B do item anterior. A Figura 56 ilustra os conjuntos testados e os valores do conjunto “nunca vistos”.

Figura 56 – Descrição das etapas de inclusão de padrões no conjunto de treinamento considerando a inclusão do parâmetro FS

Análise de PAF

Caso B

Valores do conjunto de treinamento
(20% para o conjunto validação)

ORIENTAÇÃO	PAF	T_{VIS}	FS
LESTE (90°)	20%	25%	0,467
NORTE (0°)	80%	57%	0,62
SUL (180°)	50%	91%	0,898
OESTE (270°)	35%		
NORTE (359°)	65%		

Análise de T_{VIS}

Caso B

Valores do conjunto de treinamento
(20% para o conjunto validação)

ORIENTAÇÃO	PAF	T_{VIS}	FS
LESTE (90°)	20%	25%	0,467
NORTE (0°)	50%	91%	0,898
SUL (180°)	80%	57%	0,62
OESTE (270°)		45%	0,602
NORTE (359°)		74%	0,623

Conjunto “nunca vistos” (NV)

NV 3
40%
70%

Conjunto “nunca vistos” (NV)



NV 3 T_{VIS}	NV 3 FS
54%	0,62
88%	0,819

Nos gráficos da Figura 57, foram circulado em verde os casos em que a inclusão do FS melhorou o desempenho da rede; em amarelo, os não conclusivos, visto que, para os conjuntos ordenados e randômicos, os resultados foram conflitantes; e, em vermelho, os que tiveram aumento de erros. Como se pode perceber, em especial no conjunto “nunca vistos”, os erros aumentaram para PAF (ver Figura 57a) e diminuíram para T_{VIS} (ver Figura 57b). Esse padrão se repetiu tanto para erro absoluto como para quadrático médio e desvio padrão. Os resultados apontaram que a inclusão do parâmetro Fator Solar é benéfica para a previsão de “novos vidros” (T_{VIS}), mas prejudicial para a previsão de “aberturas de novas dimensões” (PAFs).

Como FS é uma propriedade do vidro e, portanto, desconexa do PAF, a adição dessa informação aumentou a complexidade e, apesar de ter melhorado a convergência (treinamento), piorou a generalização para os PAFs “nunca vistos”. Nesse caso, talvez o número de neurônios na camada oculta deva ser revisto para que a rede possa melhorar seu desempenho. Por outro lado, no caso de T_{VIS} , em que os casos “nunca vistos” a serem estimados envolvem novos vidros, os resultados

melhoraram. Essa melhora pode ser observada nos três conjuntos da rede.

Figura 57 – Efeito da inclusão do parâmetro FS nas redes, separado por conjunto de treinamento e por parâmetro de saída para PAF e T_{VIS}




Com isso, pode-se inferir que nem sempre aumentar a quantidade de informações sobre determinado parâmetro da edificação, nesse caso o vidro, irá melhorar o desempenho do modelo. Essa observação pode estar ligada ao número de padrões. Por exemplo, as redes que possuíam cinco vidros em seu conjunto de treinamento e três aberturas se beneficiaram da informação adicional, já as que tinham três vidros e cinco PAFs ajustaram seus pesos de maneira a aprender melhor as relações segundo os diferentes PAFs. Dessa forma, a informação adicional sobre o vidro acabou por tornar-se ruidosa e por aumentar a complexidade da rede desnecessariamente e prejudicar seu desempenho.

5.3.7.2 Resultados da ação 2 – isolamento de cada um dos parâmetros de saída em redes individuais

Diante das diferenças observadas até aqui no desempenho de cada parâmetro de saída para uma mesma rede neural, observou-se o efeito de se isolarem os parâmetros de saída da rede. A combinação escolhida para esse teste foi a descrita na Figura 47, p.189, do subitem anterior, referente ao conjunto de teste para PAF, por ser a variável mais influente nos ganhos de calor e de luz.

A Figura 58 exibe os resultados para essas redes. A série de barras azuis corresponde aos parâmetros de saída, todos em uma mesma rede (configuração adotada na ação (1) deste subitem, p. 202). Já a série de barras vermelhas corresponde a três configurações individuais de redes neurais: a primeira, com o parâmetro de saída Consumo Total; a segunda, com Resfriamento; e a terceira, com Iluminação. A configuração de rede com o parâmetro Aquecimento de forma individualizada não foi testada, visto que os valores de aquecimento foram sempre ruidosos.

Figura 58 – Comparação entre redes com todos os parâmetros de saída e com cada parâmetro de forma isolada



Como se pode notar, os parâmetros de saída de Consumo Total e Iluminação aumentaram seu potencial de predição, especialmente de Iluminação. Por outro lado, a previsão do Consumo para Resfriamento piorou. Como o Consumo total abrange todos os outros e é completo em si mesmo (balanço), quando isolado, torna a rede mais simples e melhora o seu desempenho. Como foi possível constatar através deste capítulo, esse foi o parâmetro de saída que apresentou menores erros para todos os casos; logo, ao ser isolado, o ajuste de pesos é desonerado de se ajustar aos outros parâmetros mais difíceis de serem modelados, melhorando o desempenho da rede.

A Iluminação, que não depende de nenhum outro parâmetro, quando isolada, melhorou significativamente o desempenho da rede, em virtude da simplificação do ajuste de pesos, descrita anteriormente.


Já para o Resfriamento a simplificação do ajuste de pesos, ao isolar o parâmetro de saída, resultou em desempenho inverso. Como o Resfriamento varia de acordo com o padrão de uso do sistema artificial (carga interna gerada), que no caso deste trabalho é regido pela disponibilidade de iluminação natural, esse parâmetro responde melhor quando agrupado com Iluminação ou, pelo menos, com Consumo Total. Assim, ao ajustar os pesos objetivando acertar os padrões-alvo de Resfriamento e Iluminação, por exemplo, a rede “aprende” melhor.

5.3.7.3 Resultados da ação 3 – proposição de redes neurais individuais para cada orientação

Como a Orientação é o parâmetro considerado mais crítico deste estudo, testaram-se redes individuais para cada orientação. O mesmo conjunto de simulações paramétricas da ação anterior foi reagrupado conforme as orientações, e foram geradas redes neurais individuais para cada orientação. Para essa etapa da investigação, retomou-se a arquitetura de rede com os quatro parâmetros de saída para a mesma rede.

Na Figura 59, pode-se observar que, ao separar as orientações em diferentes redes, o desempenho das redes melhorou. Não houve regularidade na ordem do melhor para o pior desempenho por orientação. A única observação que se pode fazer é de que o erro que mais diminuiu para Aquecimento foi o da orientação Sul, que, devido à menor exposição à insolação, consumiu mais para aquecimento. Para Resfriamento, foram os erros das fachadas Oeste e Norte que consumiram mais. Para Iluminação, a maior redução de erro ocorreu para a fachada Norte, que, em princípio, teve maior disponibilidade de luz, apresentando menor consumo com iluminação. O Consumo Total seguiu a tendência do Resfriamento.

Figura 59 – Comparação entre redes com todas as orientações agrupadas ou isoladas



5.3.7.4 Resultados da ação 4 – refinamento do número de neurônios na camada interna e do algoritmo de otimização


A combinação escolhida para este teste foi a descrita na Figura 47, p. 189, do subitem anterior, referente ao conjunto de teste para PAF. Essa configuração possuía seis neurônios na camada oculta, definidos pela ferramenta do EasyNN-plus. Quanto ao refinamento do número de neurônios na camada interna, chegou-se a dois valores ao aplicar as heurísticas descritas na Equação 6, p. 82, e na Equação 7, p. 83. Aplicando-se a primeira, de Hecht-Nielsen, chegou-se a sete neurônios ($N_v = 3$); e, aplicando-se a segunda, de Upadhyaya-Eryurek, a 18 ($N_v = 3$ e $P = 58$). Como os resultados foram bastante diferentes, calculou-se a média entre os dois, chegando-se a 12 neurônios. Diante desse valor, optou-se por testar a rede com 10 neurônios, que foi a quantidade de neurônios para a rede utilizada no Capítulo 4. Quando do teste do número de neurônios na camada oculta apresentado no item 5.3.4, ação (3), p. 172, testaram-se a opção com 10 neurônios; entretanto, a arquitetura da rede compunha-se de apenas dois neurônios na camada de entrada (Orientação e Abertura Efetiva) e seis na camada de saída (os quatro de energia e os dois de iluminação).

O aumento do número de neurônios para essa configuração de rede melhorou significativamente o desempenho da rede para todos os parâmetros de saída. As séries de barras azuis e vermelhas da Figura 60a e b correspondem aos erros EQM e EPAM dessas soluções.

Como descrito no subitem 5.2.7, p. 160, aplicaram-se os algoritmos de otimização Levenberg-Marquardt e de Regularização Bayesiana para a arquitetura de rede com 10 neurônios na camada oculta. Como se pode observar na Figura 60a e b, os algoritmos Levenberg-Marquardt e Regularização Bayesiana, em geral,

apresentaram desempenho minimamente superior ao do Gradiente Descendente (diferença inferior a 1% em termos absolutos). A Regularização Bayesiana, por sua vez, apresentou erros menores que Levenberg-Marquardt para Resfriamento e Iluminação e maiores para Consumo Total e Aquecimento. Vale ressaltar que os dois últimos algoritmos são mais rápidos que o Gradiente Descendente, como explanado no item 2.3.6, p. 83, do capítulo de revisão bibliográfica.

Figura 60 – Comparação entre as redes Gradiente Descendente com 6 e 10 neurônios e para as redes Levenberg-Marquardt e Regularização Bayesiana



Legenda:

- Gradiente Descendente - EasyNN-plus 6 neurônios
■ Gradiente Descendente - EasyNN-plus 10 neurônios
- Levenberg-Marquardt - 10 neurônios
■ Regularização Bayesiana - 10 neurônios

Diante da significativa melhora da rede Gradiente Descendente quando do aumento do número de neurônios, plotaram-se gráficos de barra com os erros do período (ver equação 12) para todos os casos apresentados à rede, destacando-se o padrão de saída e o sinal do erro, de acordo com a Figura 61 e a Figura 62. Entretanto, não foi possível observar nenhuma tendência quanto aos sinais para os conjuntos de treinamento, validação e teste. Essa observação reforça a importância de se testar o número de neurônios para cada configuração de rede. A Heurística Hecht-Nielsen indicou um número de neurônios muito próximo ao indicado pela ferramenta do EasyNN-plus (caso com seis neurônios); entretanto, pode-se observar que esse número serve apenas como ponto de partida para a definição de nós ocultos, pois, através do ajuste do número desses neurônios, o desempenho da rede pode ser melhorado significativamente.

Figura 61 – Verificação dos erros e_t de cada caso individualmente destacando o sinal para Gradiente Descendente de seis neurônios





Figura 62 – Verificação dos erros e_t de cada caso individualmente destacando o sinal para Gradiente Descendente de 10 neurônios



5.4 CONSIDERAÇÕES FINAIS SOBRE O CAPÍTULO

Neste capítulo foram apresentados os detalhes do método e os resultados para a investigação sistemática sobre as particularidades das principais variáveis da descrição do edifício com relação às redes neurais artificiais. Para a organização das etapas da investigação sistemática, os resultados foram apresentados em grupos de ações realizadas. Primeiramente, definiram-se as variáveis-chave que compuseram a investigação. Em seguida, foi feita uma comparação entre as configurações de RNA do capítulo anterior gerada no MATLAB e a configuração padrão, utilizando-se a ferramenta de definição de número de neurônios na camada oculta do EasyNN-plus. Então, foram definidos os cinco conjuntos de ações que visaram

responder às perguntas de pesquisa listadas no início deste capítulo. Os resultados desse conjunto de ações permitiram responder às perguntas que são aqui compiladas. A pergunta principal é respondida pelo conjunto de respostas das perguntas-base e das perguntas secundárias.

Como as redes neurais podem modelar variáveis que operam em diferentes escalas? (pergunta-base)

Para a modelagem de diferentes escalas, as particularidades das variáveis adotadas devem ser analisadas e tratadas de forma que a rede possa aprender os padrões. A variável Orientação é, sem dúvidas, a mais complexa. Devido a sua escala polar, a adição da referência 359⁰ N mostrou-se adequada ao passar a informação de polaridade à rede. O estudo das particularidades do fenômeno e seus efeitos conforme a combinação das variáveis é uma importante ferramenta para identificar possíveis dificuldades no aprendizado da rede e, assim, direcionar as providências para melhorar os subsídios para o efetivo aprendizado da rede.

Como a seleção de variáveis de consumo para cada uso final pode influenciar o poder de predição da rede neural? (pergunta 1)

Observou-se que os parâmetros de saída apresentaram relação entre si ao influenciarem o ajuste dos pesos por meio da retropropagação do erro. Dessa forma, parâmetros de saída que se relacionam podem interferir positivamente no desempenho do outro. Essa conclusão pode ser notada especialmente em relação ao Resfriamento e à Iluminação.

Qual é o efeito de se agruparem ou não as variáveis de entrada fisicamente correlacionadas? (pergunta 2)

O agrupamento de variáveis correlacionadas pode ser um complicador para o aprendizado da rede, visto que, ao agrupar as variáveis, um maior número de exemplos se faz necessário (a exemplo da Abertura Efetiva). A adoção de valores mínimos, médios e máximos para o treinamento (a fim de evitar extrapolação) pode não ser suficiente, demandando uma análise das combinações dos parâmetros que geram a variável combinada a fim de fornecer subsídios adequados ao treinamento da rede.

Como parâmetros de saída de diferentes naturezas podem ser mais facilmente preditos pela rede neural? (pergunta 3)

Nesta etapa do estudo, os parâmetros de energia e iluminação natural apresentaram desempenho bastante distinto para todos os casos de estudo, sendo os parâmetros de energia mais facilmente modelados

pela rede. A adição de variáveis de diferentes naturezas em um mesmo modelo aumentou a sua complexidade, dificultando o aprendizado da rede e prejudicando o seu desempenho.

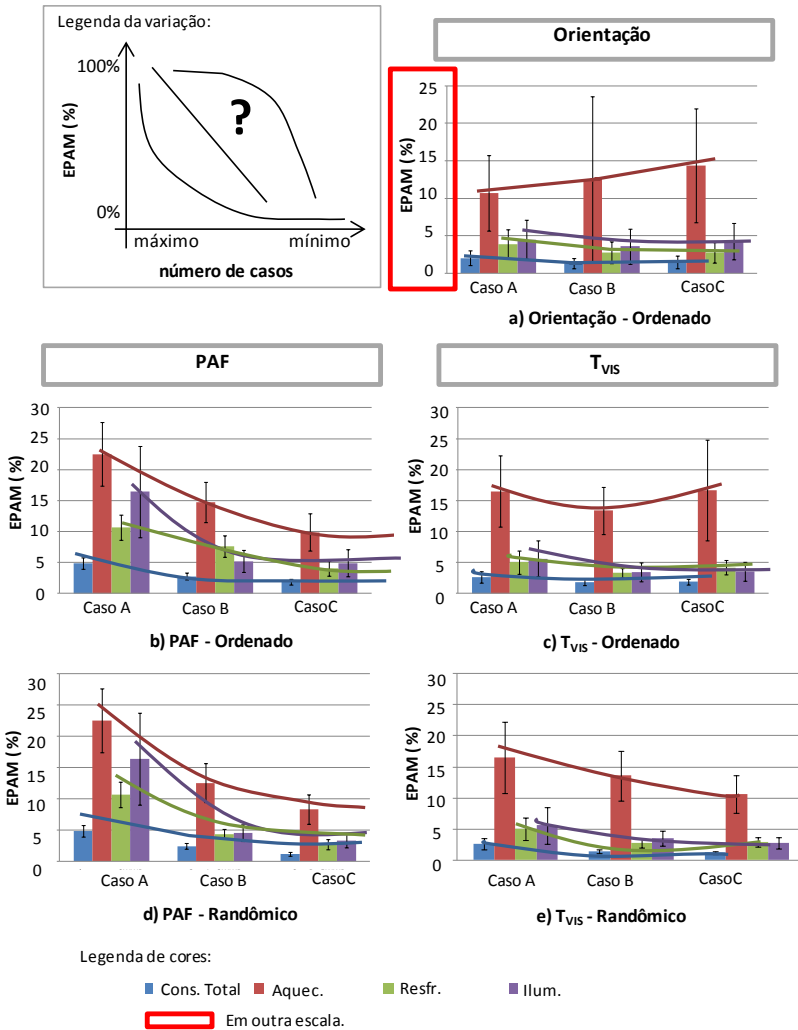
Como os parâmetros da arquitetura da RNA podem influenciar o seu desempenho? (pergunta 4)

A arquitetura da rede é de fundamental importância para o seu desempenho. Heurísticas (equações ou ferramentas de programas) podem auxiliar na sua definição. Entretanto, testes complementares são necessários para verificar a adequabilidade da arquitetura indicada. O número de camadas ocultas influencia menos que o número de neurônios ocultos, confirmando o que se observa na bibliografia, na qual autores recomendam uma camada como suficiente para modelar a maioria dos problemas não lineares. Quanto ao critério de parada, critérios vinculados ao conjunto de validação mostraram-se mais seguros que vincular o encerramento aos erros do treinamento de forma a evitar o treinamento excessivo. Redes com menores erros no treinamento e na validação não necessariamente foram as melhores para a generalização (conjunto “nunca vistos”). Essa relação, por muitas vezes, foi inversamente proporcional. Portanto, critérios de treinamento que permitam determinada magnitude de erro podem resultar em redes mais eficientes em seu desempenho global.

Como diferentes parâmetros podem precisar de diferentes quantidades e intervalos de variação para o aprendizado da rede neural? (pergunta 5)

Os exemplos analisados mostraram que cada variável apresenta uma função particular da relação entre desempenho e número de exemplos. Das três variáveis estudadas, Orientação e T_{VIS} poderiam ser representadas por função semelhante, apesar de que a função que representaria Orientação seria mais prolongada devido a uma maior variação no número de casos adotados, ver Figura 63a, c, e e. Para ambos os casos, o final da curva da função é marcado pela redução do desempenho. PAF apresentaria uma curva mais acentuada e com tendência linear no final, ver Figura 63b e d. T_{VIS} foi a variável que mostrou precisar de menos exemplos no treinamento. Logo, para alguns parâmetros, o aumento excessivo de exemplos pode inclusive piorar o modelo. Além disso, conforme as variáveis que estão sendo combinadas no modelo, essa curva pode mudar e novas quantidades de exemplos podem ser necessárias para que a rede possa aprender os padrões.

Figura 63 – Estudo das curvas de tendência da redução do erro da rede para o conjunto “nunca vistos” frente aumento do número de casos do treinamento



6. INVESTIGAÇÃO SISTEMÁTICA DAS POSSIBILIDADES E DAS LIMITAÇÕES DAS RNAs – CONTEXTO DO EDIFÍCIO

O presente capítulo dá continuidade à investigação sistemática da metamodelagem das principais variáveis-chave da iluminação natural segundo os objetivos deste trabalho, entretanto abordando variáveis do contexto do edifício. A exemplo do capítulo anterior, será apresentado um resumo da estrutura do capítulo relacionando as perguntas de pesquisa e os itens dos resultados e das ações conduzidas para respondê-las. O esquema conceitual de aplicação da etapa 3 do método foi atualizado para a aplicação aqui proposta. Os resultados serão apresentados de acordo com os respectivos grupos de ações.

6.1 INTRODUÇÃO

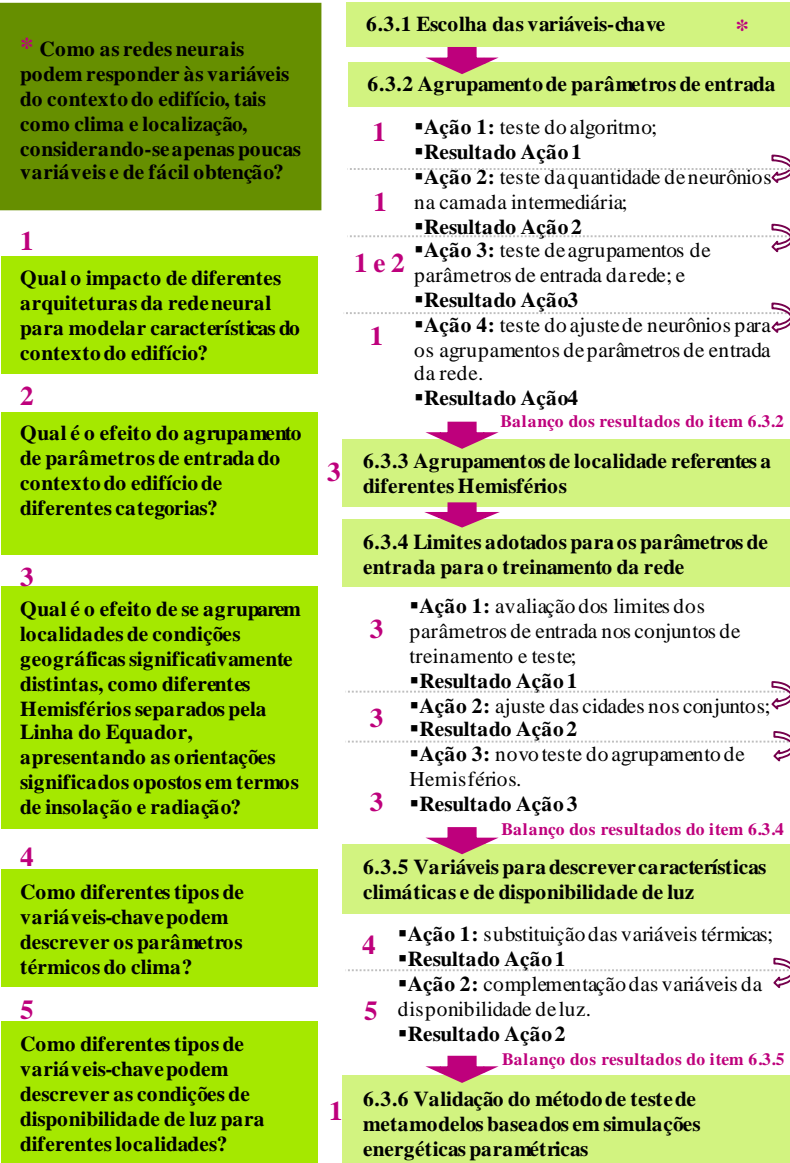
Um mesmo ambiente, com a mesma janela, irá apresentar padrões de iluminação completamente diferenciados dependendo da localidade em que estiver inserido, em especial devido às condições geográficas e às condições atmosféricas locais. Buscando investigar as possibilidades de modelagem das variáveis do contexto do edifício, partiu-se da escolha de variáveis-chave críticas relacionadas ao consumo energético com base na iluminação natural. Da mesma forma que no capítulo anterior, optou-se pela realização das simulações energéticas apenas no programa EnergyPlus, priorizando a agilidade à precisão. Quanto às redes neurais, manteve-se a abordagem de observar padrões de comportamento baseados nos resultados de conjuntos de RNA.

6.2 DETALHAMENTO DO MÉTODO

A Figura 64 apresenta a estrutura de desenvolvimento deste capítulo, seguindo o mesmo padrão de apresentação do capítulo anterior. Da mesma forma que no Capítulo 5, a principal pergunta de pesquisa que foi apresentada no capítulo do método geral, item 3.2, p. 105, foi destacada com um asterisco no quadro de tom mais escuro, agora verde, na coluna da esquerda da figura. Essa pergunta originou cinco outras perguntas, que nortearam o desenvolvimento deste capítulo e foram destacadas nos demais quadros verdes da mesma coluna. A relação de numeração de itens, ações e setas indicativas da coluna da direita segue a mesma representação descrita no item 5.2, p.147.

Figura 64 – Resumo da avaliação sistemática: contexto do edifício

CONTEXTO DO EDIFÍCIO



Como as redes neurais podem responder às variáveis do contexto do edifício, tais como clima e localização, considerando-se apenas poucas variáveis e de fácil obtenção?

1
Qual o impacto de diferentes arquiteturas da rede neural para modelar características do contexto do edifício?

2
Qual é o efeito do agrupamento de parâmetros de entrada do contexto do edifício de diferentes categorias?

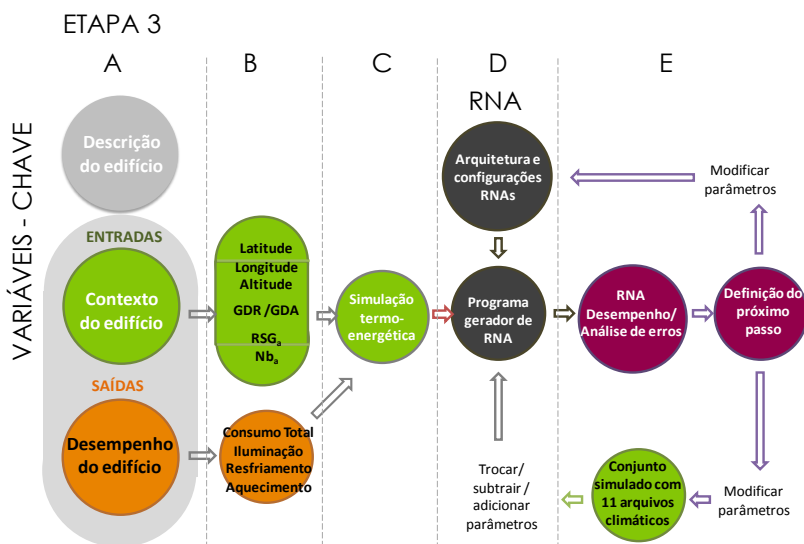
3
Qual é o efeito de se agruparem localidades de condições geográficas significativamente distintas, como diferentes Hemisférios separados pela Linha do Equador, apresentando as orientações significados opostos em termos de insolação e radiação?

4
Como diferentes tipos de variáveis-chave podem descrever os parâmetros térmicos do clima?

5
Como diferentes tipos de variáveis-chave podem descrever as condições de disponibilidade de luz para diferentes localidades?

Para responder às perguntas de pesquisa, adotaram-se as ações metodológicas apresentadas na Figura 65 (baseada na Figura 12, p. 103). Primeiramente, isolaram-se os grupos das variáveis-chave que seriam trabalhadas, nesse caso contexto do edifício e desempenho do edifício. As variáveis da descrição do edifício foram definidas e mantidas fixas de forma a não interferirem nas análises. Da mesma forma que no capítulo anterior, as variáveis do desempenho do edifício foram tratadas superficialmente, pois exercem papel secundário nesta etapa do trabalho e são estudadas de forma aprofundada no Capítulo 7.

Figura 65 – Aplicação da etapa metodológica 3: contexto do edifício



Fonte: Autor.

A escolha das variáveis-chave do contexto do edifício baseou-se na descrição da localidade, das características térmicas e da disponibilidade de luz (condição de céu), que influenciam o consumo energético considerando a iluminação natural. As variáveis de desempenho abordaram os principais usos finais do consumo energético em edificações comerciais.

Para a representação de diferentes localidades e climas, foram escolhidas 11 cidades: nove delas são capitais brasileiras, estando localizadas em sete zonas bioclimáticas diferentes; duas delas localizam-se no Hemisfério Norte e foram escolhidas pelo rigor climático –

Vancouver, pelas baixas temperaturas e pela elevada umidade relativa, e Phoenix, pelas altas temperaturas e pela baixa umidade relativa do ar. Dessa forma, buscou-se testar os limites das redes neurais.

Da mesma forma que no capítulo anterior, a geração dos dados para o treinamento da rede foi feita através de simulações paramétricas utilizando-se a Macro adaptada de Westphal (2012) e o programa EnergyPlus. A mesma geometria-base, ilustrada na Figura 23, p. 151, foi adotada. Os modelos paramétricos foram simulados para as 11 cidades.

Para a operacionalização da aplicação das redes neurais, utilizou-se o programa EasyNN-plus em conjunto com o programa MATLAB. Dessa forma, foi possível aliar o uso de ferramentas práticas, como a da definição automática do número de neurônios ocultos do EasyNN-plus, com a liberdade de programação do MATLAB.

Os efeitos das perturbações nas redes neurais foram avaliados através de análise dos erros, da mesma forma que nos capítulos anteriores. O número de redes para cada caso variou entre 5 e 10, conforme o tempo de processamento.

As ações conduzidas para responder às perguntas geradas foram separadas em cinco grupos:

- avaliação do agrupamento de parâmetros de entrada de diferentes categorias para a descrição da localização e das características climáticas;
- investigação das potencialidades de agrupamentos de localidade referentes a diferentes Hemisférios em uma mesma RNA;
- investigação da importância dos limites adotados para os parâmetros de entrada para o treinamento da rede;
- experimentação de diferentes variáveis para descrever características climáticas e de condição de céu; e
- validação do método de teste de metamodelos baseados em simulações energéticas paramétricas.

Os detalhes metodológicos da seleção de variáveis-chave e dos cinco grupos de ações listados são apresentados nos subitens a seguir (item 6.2.1 ao 6.2.6).

6.2.1 Escolha das variáveis-chave

Da mesma forma que no capítulo anterior, determinaram-se quais os grupos da Figura 3, p. 61, faziam parte do contexto do edifício. Dentro desses grupos, elencaram-se as variáveis escolhidas.

6.2.2 Agrupamento de parâmetros de entrada

Como na última ação do capítulo anterior, item 5.3.7, ação (4), testou-se a adequabilidade dos algoritmos Gradiente Descendente, Levenberg-Marquardt e Regularização Bayesiana.

Os parâmetros de entrada e saída foram mantidos os mesmos para a comparação entre os algoritmos. Considerou-se uma camada oculta e foi definido o número de neurônios seguindo a indicação da ferramenta do EasyNN-plus e da terceira heurística (baseada em fóruns de discussão), apresentada no item 2.3.5 do capítulo da revisão bibliográfica, através da Equação 8. Optou-se por esse teste porque as abordagens Hecht-Nielsen e Upadhyaya-Eryurek testadas no capítulo anterior divergiram significativamente entre si.

Cada um dos três algoritmos possui diferentes possibilidades de critério de parada do treinamento, inerente ao seu conceito matemático. A Regularização Bayesiana, por exemplo, não utiliza conjunto de validação; dessa forma, o critério de parada comum aos três algoritmos adotados foi o número máximo de épocas, determinado em 1.000. Os outros critérios de parada foram mantidos de acordo com os valores padrão do MATLAB (ver Anexo do trabalho). Para efeito de teste, o algoritmo Gradiente Descendente, que vinha sendo trabalhado mais intensamente no capítulo anterior, também foi testado com o critério de parada: *até que 30% do conjunto de validação esteja dentro do limite de erro.*

Visando ao aprofundamento do teste do número de neurônios, a mesma configuração de rede foi testada para oito proporções de número de neurônios: média entre quantidade de parâmetros de entrada e saída; 1,5, 2, 2,5, 3, 4, 5 e 10 vezes o número de parâmetros de entrada. O algoritmo utilizado foi a Regularização Bayesiana. Os efeitos foram avaliados conforme o impacto na convergência e na generalização da rede.

Para o teste do agrupamento de variáveis de entrada de diferentes categorias, manteve-se a mesma configuração de rede. Adotaram-se o algoritmo Regularização Bayesiana e a proporção de quatro vezes o número de variáveis de entrada para a definição da quantidade de neurônios na camada intermediária.

Para os testes de agrupamentos, consideraram-se três categorias: localização geográfica, características térmicas e características de disponibilidade de luz (condições de céu). Foram propostos três tipos de agrupamentos: todas as categorias (solução-base), cada categoria individualmente e as categorias agrupadas duas a duas. Esses

agrupamentos resultaram em sete configurações de rede a serem testadas. Primeiramente, as redes foram testadas com o mesmo número de neurônios na camada interna. Em um segundo momento, testaram-se novamente as redes, ajustando-se a quantidade de neurônios ocultos conforme o número de parâmetros na camada. Esse ajuste foi feito proporcionalmente à solução-base.

6.2.3 Agrupamentos de localidade referentes a diferentes Hemisférios

Considerando-se a mesma configuração de rede da solução-base do subitem anterior, foram propostas duas soluções de redes neurais: uma com cidades dos Hemisférios Norte e Sul no conjunto de treinamento e uma apenas com cidades do Hemisfério Sul. O conjunto “nunca vistos” foi mantido o mesmo para os dois casos; para este conjunto, foram escolhidas duas cidades do Hemisfério Sul cujos padrões não foram apresentados à rede no treinamento, mas pertenciam à mesma zona bioclimática (ABNT, 2005b) de alguma cidade que fez parte desse treinamento.

6.2.4 Limites adotados para os parâmetros de entrada para o treinamento da rede

A definição de quais cidades seriam utilizadas para testar as redes baseou-se na variável latitude, que deveria estar entre os valores extremos das latitudes das cidades do conjunto de treinamento. Além disso, a cidade deveria estar localizada na mesma zona bioclimática de alguma dessas cidades. Apesar da adoção de vários parâmetros de entrada referentes ao clima, esses não variam para edificações localizadas na mesma cidade (variam de cidade para cidade, mas não são combinados entre si, pois representam os dados da cidade). Assim, fez-se necessário verificar se os critérios para a seleção das cidades foram suficientemente adequados. Para a avaliação dos limites dos parâmetros de entrada nos conjuntos de treinamento e teste, os valores numéricos de cada parâmetro de entrada foram plotados em gráficos de pontos. Como para este trabalho a abordagem dos efeitos dos parâmetros climáticos é anual e baseada em simulação energética computacional, utilizaram-se como base os arquivos climáticos das diferentes cidades, dos quais foram extraídas as informações sobre cada uma delas. Assim, os valores dos limites abordados no treinamento para cada variável de entrada foram avaliados de forma conjunta a fim de verificar as variáveis que pudessem ou não levar a rede à extrapolação.

Os pontos foram identificados com cores segundo o Hemisfério de localização e o conjunto de treinamento ou teste. Com base nessa análise, uma cidade do conjunto de teste foi realocada no conjunto de treinamento e, por sua vez, a cidade localizada na mesma zona bioclimática que estava no conjunto de treinamento migrou para o conjunto de teste. Novos testes sob a ótica de agrupamento de Hemisférios foram realizados, verificando o impacto da alteração para as duas configurações de rede.

6.2.5 Variáveis para descrever características climáticas e de disponibilidade de luz

Neste item adotou-se a mesma configuração-base de rede do item 6.2.2, p. 217. Para a verificação da adequabilidade das variáveis-chave escolhidas para a modelagem das características térmicas do clima, testou-se a aplicabilidade de outro conjunto baseado em características climáticas primárias, ou seja, características que pudessem ser medidas. Foram escolhidos valores dos meses de janeiro e julho para indicar condições de verão e inverno, e, conseqüentemente, captar maiores variações de frio e calor.

Já para a verificação da adequabilidade das variáveis-chave escolhidas para a modelagem das características de disponibilidade de luz, apenas se incluiu mais uma variável para complementar informações sobre as condições de céu.

Adicionalmente, para as duas ações foi proposta uma comparação com uma rede Gradiente Descendente e com o critério de parada: *até que 30% do conjunto de validação esteja dentro do limite de erro*, similar ao que foi feito no item 6.2.2. Nesse caso, a definição do número de neurônios na camada oculta foi feita através do EasyNN-plus.

6.2.6 Validação do método de teste de metamodelos baseados em simulações energéticas paramétricas

A abordagem de teste de RNAs recomendada pela literatura vem sendo adotada por muitos autores que aplicaram redes neurais para a metamodelagem baseada em simulações termoenergéticas paramétricas, como destacado no item 2.3.2, p. 77. Entretanto, como já justificado neste trabalho no item 3.4.3, julga-se o método insuficiente para verificar as limitações das RNAs, a partir do que foi proposta a avaliação pelo conjunto “nunca vistos”.

Assim, optou-se por realizar uma comparação entre o método da literatura e o conjunto “nunca vistos” a fim de verificar o impacto da

escolha do conjunto de testes para garantir a robustez do modelo. Essa informação é especialmente importante para a verificação da aplicabilidade das redes neurais para diferentes climas, visto que o esforço computacional para gerar dados para um metamodelo que fosse representar um país ou uma região, por exemplo, deve ser levado em conta no estudo de viabilidade do metamodelo.

Para tal, o mesmo conjunto de dados que foi trabalhado neste capítulo e a mesma configuração da rede-base do item 6.2.2, p. 217, foram adotados. O resultado da abordagem da literatura foi comparado com a rede compatível do item 6.2.4, p. 218.

6.3 RESULTADOS

Primeiramente, são apresentados os resultados da escolha das variáveis-chave e, na sequência, os resultados obtidos nos cinco grupos de ações já descritos.

6.3.1 Escolha das variáveis-chave

As variáveis do contexto da edificação selecionadas foram

- a localização geográfica: latitude, longitude e altitude;
- as características térmicas: Graus Dia de Resfriamento (GDR) e Graus Dia de Aquecimento (GDA);
- a disponibilidade de luz: Radiação Solar Global Acumulada (RSG_a) e a Nebulosidade Acumulada (Nb_a).

As últimas variáveis listadas de abordagem acumulada correspondem à soma de todas as ocorrências ao longo do ano. Testes preliminares apontaram esta abordagem como mais indicada ante o uso de frequências de ocorrência. Vale salientar que, como os dados lidos pela RNA são normalizados, para a rede esses valores são iguais aos dados referentes à Radiação Solar Global Média e à Nebulosidade Média.

Variáveis da descrição do edifício foram fixadas de acordo com as variáveis descritas no item 5.3.6 (ver Figura 47, p. 189), tendo-se fixado para a Orientação as quatro orientações cardeais e 359° N; para o PAF, os cinco valores apresentados no caso A; e para a T_{VIS} , os cinco valores do caso B ilustrados na Figura 47, p. 189. As variáveis de desempenho do edifício foram as mesmas do capítulo anterior, limitadas às variáveis referentes ao consumo energético: Consumo Total, Aquecimento, Resfriamento e Iluminação.

De acordo com a classificação de Heschong (2011), exposta na Figura 3, p. 61, as variáveis de localização geográfica fazem parte do grupo A (descrição do espaço – subgrupo orientação) e as variáveis térmicas e de disponibilidade de luz integram o grupo C (parâmetros de entrada de clima). As variáveis de consumo pertencem ao grupo 2 (impactos energéticos). Apesar de as variáveis de localização geográfica estarem alocadas no subgrupo Orientação, acredita-se que deveria ser criado um novo subgrupo com essa nomenclatura e serem transferidas as variáveis Latitude e Longitude para esse subgrupo. A variável Altitude deve ser incluída, visto que é relacionada com características de nebulosidade que influenciam a disponibilidade de luz. As demais variáveis, quando aplicáveis, foram mantidas constantes.

A Tabela 10 exhibe os valores adotados para cada uma das variáveis-chave empregadas para cada cidade escolhida para treino e teste das RNAs. A tabela também indica a zona bioclimática (ZB) em que a cidade está inserida. O parâmetro Latitude foi utilizado como referência na definição das cidades que serviram para testar a rede a fim de evitar que as redes tivessem que extrapolar valores. Inicialmente, os casos simulados para as cidades de São Paulo e de Salvador foram separados para testar a rede como conjunto “nunca vistos”, destacados em negrito na mesma tabela.

Tabela 10 – Dados das cidades escolhidas para o treinamento e o teste das redes neurais

CIDADES	Localização Geográfica			Temperatura		Disponibilidade de luz	
	Latitude (°)	Longitude (°)	Altitude (m)	GDA (°C)	GDR (°C)	RSG _a (Wh/m ² n)	Nb _a (décimos n)
ZB 1 - Curitiba	-25,5	-49,2	908	21	427	1520920	64912
ZB 2 - Belo Horizonte	-19,9	-44	785	0	1487	1915844	41260
ZB 3 - Florianópolis	-27,7	-48,5	7	2	1135	1647171	56937
ZB 3 - São Paulo (teste-NV)	-23,6	-46,6	803	1	854	1678614	58717
ZB 4 - Brasília	-15,9	-47,9	1061	0	1219	1962601	49949
ZB 5/8 - Rio de Janeiro	-22,9	-43,2	-3	0	2184	1843298	47841
ZB 6 - Campo Grande	-20,5	-54,7	556	2	2236	1927772	44176
ZB 7 - Cuiabá	-15,7	-56,1	182	0	3206	1948652	50085
ZB 8 - Salvador (teste- NV)	-13	-38,5	51	0	2901	1926311	48568
ZB - Vancouver	49,2	-123,2	2	901	5	1229518	59161
ZB - Phoenix	33,5	-112	337	28	2661	2094203	27787

Fonte: Adaptado de: Arquivos climáticos (US-DOE, 2011).

6.3.2 Agrupamento de parâmetros de entrada

Como descrito no item 6.2.2, para este grupo adotaram-se quatro ações:

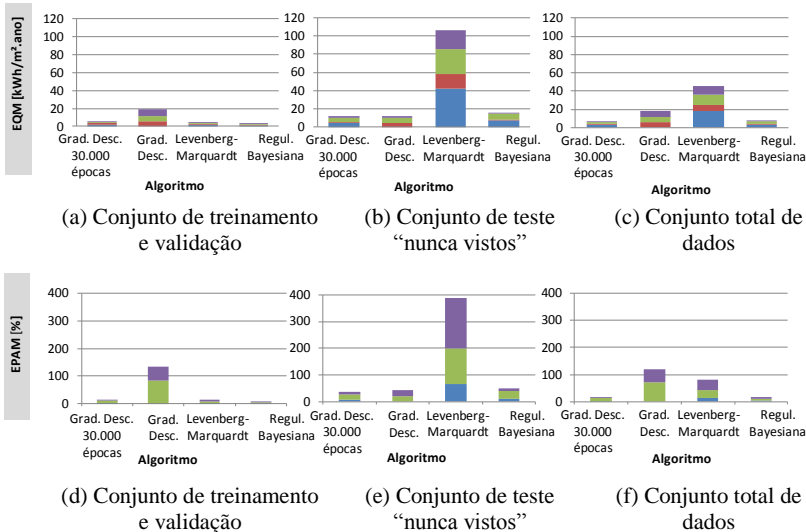
- (1) teste do algoritmo;
- (2) teste da quantidade de neurônios na camada intermediária;
- (3) teste de agrupamentos de parâmetros de entrada da rede; e
- (4) teste do ajuste de neurônios para os agrupamentos de parâmetros de entrada da rede.

6.3.2.1 Resultados da ação 1 – teste do algoritmo

A Figura 66 apresenta os gráficos de EQM e EPAM separados por conjunto de treinamento e teste, e da rede de forma global. O erro percentual para o parâmetro de saída Aquecimento foi desconsiderado nessa análise devido ao seu resultado ruidoso. A diferença entre os resultados dos conjuntos de treinamento e teste foi significativa, especialmente para o algoritmo Levenberg-Marquardt. Entretanto, esses

resultados correspondem à média de cinco redes neurais. Ao observar os erros de cada rede individualmente (ver Figura 67), pode-se verificar que, para esse algoritmo, três das cinco redes (RNA 1, 2 e 3) apresentaram erros muito superiores aos das demais. Entretanto, as duas outras apresentaram padrão de erro semelhante ao das redes dos outros algoritmos. Esse resultado, mais uma vez, reforça a necessidade de treinarem-se várias redes para viabilizar conclusões sobre o seu comportamento quanto às variáveis estudadas.

Figura 66 – Comparação entre os algoritmos para cada o uso final para a média das 5 RNAs



Legenda:





Figura 67 – Comparação entre os algoritmos destacando-se o uso final para cada RNA individualmente




Os algoritmos Gradiente Descendente 30.000 épocas e Regularização Bayesiana apresentaram padrão de comportamento semelhante, com erros menores no conjunto de treinamento e maiores

no conjunto “nunca vistos”. Essa tendência era esperada, sendo a diferença de desempenho entre essas duas soluções de menos de 2% quando considerada a rede em geral. Levenberg-Marquardt também apresentou essa tendência; entretanto, com erros maiores, como já justificado através da observação da Figura 67.

O Gradiente Descendente, que utilizou o mesmo critério de parada que os outros dois algoritmos (será chamado apenas de Gradiente Descendente), apresentou padrão de erros invertido, com erros maiores no conjunto de treinamento e menores no conjunto “nunca vistos”. Essa diferença de padrão, especialmente em relação ao mesmo algoritmo com treinamento mais longo (30.000 épocas), se justifica pelo fato de o treinamento mais curto não permitir o ajuste excessivo dos pesos da rede, melhorando a generalização, mas, por vezes, piorando a convergência. No balanço final da rede o desempenho inferior do conjunto de treinamento mais curto prejudicou o resultado global, especialmente porque esse conjunto é muito maior que o conjunto de teste.

Quando analisados os desempenhos dos algoritmos por variável de saída (ver Figura 68), as tendências de erro dos conjuntos de treinamento e teste foram diferentes, a avaliação para o conjunto total de dados tendeu ao padrão de erros do conjunto de treinamento. Quanto ao conjunto de treinamento, o algoritmo Regularização Bayesiana apresentou os menores erros para Resfriamento e Iluminação. Em geral, os menores erros aconteceram para a predição do Consumo Total e os maiores para a predição do Consumo para Resfriamento. O algoritmo Gradiente Descendente apresentou erros próximos a zero para Consumo Total, mas, em compensação, erros maiores para os outros parâmetros de saída, provavelmente, ao ajustar-se excessivamente a esse padrão, a rede prejudicou os demais. O conjunto de teste não apresentou padrão de erros claro; entretanto, essa tendência do Gradiente Descendente se repetiu.

Figura 68 – Comparação entre os algoritmos, destacando-se o uso final para os três conjuntos da rede



Legenda:

■ Gradiente Descendente 30,000 épocas
 ■ Gradiente Descendente
 ■ Regularização Bayesiana
 ■ Levenberg-Marquardt

Para concluir a comparação entre os algoritmos, considerou-se o esforço computacional exigido para cada um. A Tabela 11 mostra o tempo médio das 5 RNAs treinadas para cada caso e as configurações do computador utilizado para treiná-las. Como já esperado, devido ao seu conceito matemático, o algoritmo Gradiente Descendente é significativamente mais oneroso que os demais. Comparando-se as soluções Regularização Bayesiana e Gradiente Descendente 30.000 épocas, cujos desempenhos foram semelhantes para o caso estudado, o primeiro foi 36 vezes mais rápido que o segundo, sendo considerado mais vantajoso no balanço entre tempo e desempenho.

Tabela 11 – Tempo médio de processamento de cada algoritmo

TEMPO CONSUMIDO				
	Gradiente Descendente 30.000 épocas	Gradiente Descendente	Levenberg-Marquardt	Regularização Bayesiana
Tempo médio das 5 RNAs (h)	2:19	1:11	0:09	0:06
CARACTERÍSTICAS DOS COMPUTADORES				
Tipo de computador	Computador portátil			
Processador	Intel Core 2 DUO CPU			
Memória (RAM)	4 GB			
Sistema	32 Bits			

Fonte: Autor.

A diferença entre as duas abordagens apresentadas do Gradiente Descendente reforça a importância da escolha do critério de parada da rede.

Nenhum dos algoritmos apresentou desempenho constantemente melhor ou pior para todos os parâmetros de saída em todos os conjuntos avaliados, o que destaca a importância da análise particionada do desempenho da rede em vez de assumir-se a média geral da rede. Dessa forma, é possível definir com mais segurança as limitações do modelo.

A Regularização Bayesiana foi o algoritmo que apresentou resultados mais consistentes quando observados os erros quadráticos médios das redes individualmente, bem como os demais erros para as médias das redes, além do menor tempo de execução. Nas observações individuais foi o algoritmo que apresentou a menor variação entre as redes, o que leva à conclusão de que esse é o seu desempenho real para o caso apresentado, e não um desempenho atípico causado pelo início do processo de treinamento de um ponto inapropriado da superfície do erro. Apesar de ter apresentado EPAM 10% maior que o Gradiente Descendente 30.000 épocas para o conjunto “nunca vistos”, no balanço final da rede foi o que apresentou o melhor desempenho.

6.3.2.2 *Resultados da ação 2 – teste da quantidade de neurônios na camada intermediária*

O número de neurônios na camada intermediária foi definido conforme o número de nós na camada de entrada e de saída, como descrito no item 6.2.2, p. 217. As redes trabalhadas nesse conjunto de ações possuem oito parâmetros de entrada (Orientação, PAF, T_{VIS} , Latitude, Longitude, Altitude, Radiação Global Acumulada e Índice de Nebulosidade Acumulado) e quatro nós de saída (Consumo Total, Aquecimento, Resfriamento e Iluminação). Logo, a quantidade de neurônios para os testes resultou em

- média entre quantidade de parâmetros de entrada e de saída = 7 neurônios;
- 1,5 x quantidade de parâmetros de entrada = 15 neurônios;
- 2 x quantidade de parâmetros de entrada = 20 neurônios;
- 2,5 x quantidade de parâmetros de entrada = 25 neurônios;


- 3 x quantidade de parâmetros de entrada = 30 neurônios;
- 4 x quantidade de parâmetros de entrada = 40 neurônios;
- 5 x quantidade de parâmetros de entrada = 50 neurônios; e
- 10 x quantidade de parâmetros de entrada = 100 neurônios.

A Figura 69 ilustra o EPAM para os três conjuntos: treinamento, “nunca vistos” e rede em geral. No gráfico de treinamento, pode-se perceber que o aumento do número de neurônios ocultos reduz o erro para esse conjunto. Esse comportamento repetiu-se para os quatro padrões de saída. Quando se avaliou a maior diferença absoluta entre uma solução de quantidade de neurônios e a solução seguinte, a diferença mais expressiva ocorreu entre sete e 15 neurônios para todos os padrões de saída.

A regularidade no padrão dos erros, quando separados por parâmetro de saída para os diferentes números de neurônios, não se repetiu para o conjunto “nunca vistos”. Percentualmente, os maiores erros mantiveram-se para a predição do consumo por Resfriamento (mais que o dobro dos outros), enquanto Consumo Total e Iluminação se alternaram: de sete a 20 neurônios, os erros de Iluminação foram praticamente a metade dos de Consumo Total; e de 30 a 100 neurônios, essa proporção se inverteu. Considerando a soma do EPAM de todos os parâmetros de saída para o conjunto “nunca vistos”, a solução de 40 neurônios seguida da de 15 e 30 foram as que apresentarem melhores desempenhos, em torno de 50% de erro, enquanto a de 20 e 25 neurônios apresentaram os piores desempenhos, chegando a 80%.

Considerando a rede de forma global, a solução de 40 neurônios manteve-se como a que apresentou menores erros, 13%, seguida da solução de 30 neurônios, 14%, enquanto a de 20 e 25 neurônios mantiveram-se com os maiores erros, 22% e 21%, respectivamente.

Figura 69 – Comparação entre a quantidade de neurônios na camada intermediária separado por uso final para os três conjuntos da rede



Legenda:

■ Cons. Total ■ Resfr. ■ Ilum.

O aumento do número de neurônios na camada oculta aumenta a complexidade da rede e conseqüentemente o tempo de processamento. Com isso, diferenças pequenas de desempenho como a que ocorreu para os casos com 30 e 40 neurônios devem ser analisadas sob a ótica do melhor balanço entre tempo de execução e desempenho.

O conjunto de treinamento responde mais regularmente à variação no número de neurônios ocultos, apresentando um padrão de redução do erro conforme o acréscimo de neurônios. Entretanto, o aumento dos neurônios pode levar a rede a decorar padrões, prejudicando o seu poder de generalização. Como se pode ver nos gráficos de treinamento e teste, essa relação não é inversamente proporcional, posto que as redes com 20 e 25 neurônios apresentaram desempenho inferior às de 100 neurônios para o conjunto "nunca vistos".

6.3.2.3 Resultados da ação 3 – teste de agrupamentos dos padrões de entrada da rede


A avaliação do efeito de agrupamentos de diferentes características foi feita segundo os seguintes conjuntos:

- todos os parâmetros de entrada (G+T+S): Localização geográfica (G), Características térmicas (T) e disponibilidade de luz (S);
- G+T: Localização geográfica (G) e Características térmicas (T);
- G+S: Localização geográfica (G) e disponibilidade de luz (S);

- T+S: Características térmicas (T) e disponibilidade de luz (S);
- G: Localização geográfica (G);
- T: Características térmicas (T); e
- S: disponibilidade de luz (S).

A Figura 70 ilustra o EPAM destacado por agrupamento com escalas diferenciadas a fim de possibilitar a visualização dos diferentes conjuntos. Nessa figura, pode-se observar que, sob o enfoque dos parâmetros de entrada, os conjuntos de treinamento (ver Figura 70a) e “nunca vistos” (ver Figura 70b) apresentaram a mesma tendência de erros, entretanto com magnitudes diferentes, tendo o “nunca vistos” apresentado erros significativamente maiores, com variação das escalas dos gráficos de 8% para 200%. O agrupamento G+T+S foi a solução de melhor desempenho, seguida das soluções de agrupamento de duas variáveis (para todos os conjuntos). Observando o conjunto total de dados (ver Figura 70c), a Localização Geográfica (G), isoladamente, apresentou melhor desempenho que G+T, com EPAM igual a 13% e 15%, respectivamente. As características de Localização Geográfica parecem ser mais representativas que as demais, visto que, isoladamente, o desempenho de Localização Geográfica (G) foi superior aos desempenhos de Características Térmicas (T) e Disponibilidade de Luz (S). Quanto à relevância das Características de Temperatura e da Disponibilidade de Luz, a segunda parece ser mais representativa. Isso porque, quando combinadas com Localização Geográfica (G), as características térmicas (G+T) apresentaram EPAM maior que a disponibilidade de luz (G+S), 15% e 14%, respectivamente. Somado a isso, quando observadas isoladamente, as Características Térmicas (T) apresentaram EPAM de 33%, enquanto a Disponibilidade de Luz (S), de 26%.

Figura 70 – Comparação entre os agrupamentos de padrões de entrada da rede para cada uso final para os três conjuntos da rede




Legenda:



A Figura 71 ilustra o EAM destacado por parâmetro de saída, com os gráficos dos três conjuntos na mesma escala. Sob esse enfoque, para o conjunto de treinamento (ver Figura 71a), o agrupamento G+T+S foi a melhor solução para todos os padrões. Entretanto, os outros agrupamentos se alternaram no desempenho para cada parâmetro de saída. Contraintuitivamente, o agrupamento G+T apresentou menores erros para Aquecimento e Iluminação e o G+S para Resfriamento e Consumo Total. Por outro lado, quando isolados, o grupo de Características Térmicas (T) apresentou menores erros para Aquecimento e Resfriamento e o grupo de Disponibilidade de Luz (G+S) para Iluminação e Consumo Total. Quanto ao conjunto "nunca vistos" (ver Figura 71b), não foi possível observar nenhum padrão comum aos parâmetros de saída. O conjunto completo da rede (ver Figura 71c) seguiu o padrão de erros do conjunto "nunca vistos" devido à magnitude dos erros desse conjunto.

Figura 71 – Comparação entre os agrupamentos de padrões de entrada da rede para cada uso final para os três conjuntos da rede



Legenda:


Em outra escala G+T+S G+T G+S T+S G T S

O agrupamento G+T+S, em geral, apresentou melhor desempenho, especialmente para o conjunto de treinamento. Entretanto, a diferença no desempenho desse agrupamento com os agrupamentos G+S, T+S e G, quando avaliada a rede de forma completa, foi menor de 2% em termos absolutos e, para o conjunto “nunca vistos”, menor que 4%. O agrupamento das três categorias gerou uma rede maior e, conseqüentemente, mais complexa, exigindo maior esforço computacional e aumentando consideravelmente o tempo de execução (treinamento); logo, o balanço entre tempo e desempenho deve ser considerado na escolha das variáveis de entrada do modelo. Nesse caso é aconselhável considerar a avaliação do desempenho da rede por padrão de saída (ver Figura 59) a fim de priorizar o desempenho do parâmetro de saída considerado mais relevante.

6.3.2.4 Resultados da ação 4 – teste do ajuste de neurônios para os agrupamentos de parâmetros de entrada da rede

A Figura 72 ilustra os resultados através do EPAM para o ajuste de neurônios proposto para os agrupamentos. Em geral, para os três grupos, o desempenho das redes piorou, visto que os erros aumentaram com o ajuste de neurônios.

Figura 72 – Comparação entre os agrupamentos com ajuste de número de neurônios para cada uso final para os três conjuntos da rede



Legenda:

■ Cons. Total ■ Resfr. ■ Ilum.

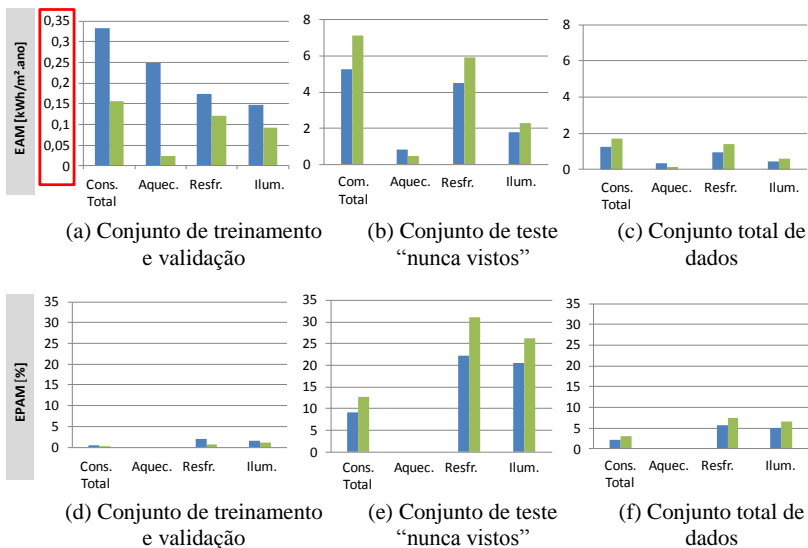
6.3.3 Agrupamentos de localidade referentes a diferentes Hemisférios

Para esta avaliação, o conjunto “nunca vistos” foi mantido; entretanto, para a solução Hemisfério Sul, as cidades Phoenix e Vancouver foram excluídas do conjunto de treinamento. A arquitetura da rede pode ser descrita por agrupamento G+T+S como parâmetros de entrada com algoritmo Regularização Bayesiana e 40 neurônios ocultos.

Os resultados da Figura 73a mostram que a solução que considera apenas o Hemisfério Sul reduziu os erros do conjunto de treinamento para todos os parâmetros de saída. Entretanto, o oposto pode ser observado no conjunto “nunca vistos” (ver Figura 73b), com exceção do parâmetro Aquecimento, que, com a separação das cidades, foi beneficiado nos dois conjuntos. A rede de forma global (ver Figura 73c) segue o padrão de erros do conjunto “nunca vistos”.

A redução dos erros no conjunto de treinamento (ver Figura 73a) com a separação das cidades por Hemisfério justifica-se por essa solução homogeneizar mais o conjunto de treinamento, facilitando a convergência da rede. Por outro lado, prejudica a generalização, refletindo na redução do desempenho do conjunto “nunca vistos” (ver Figura 73b e e). O padrão de erro referente ao EAM, observado para o Aquecimento, possivelmente, deve-se ao fato de Vancouver apresentar uma condição climática muito diferente das outras cidades avaliadas.

Figura 73 – Comparação entre as soluções com as cidades dos dois Hemisférios e apenas do Hemisfério Sul



Legenda:

0,35 Em outra escala ■ G + T + S Ambos os Hemisférios ■ G + T + S Hemisfério Sul

A escolha do conjunto de dados que irá servir ao treinamento da RNA é de suma importância para o seu desempenho final. Alimentar a rede com a maior quantidade de casos possível pode melhorar a generalização, mas valores muito extremos, como o caso de Vancouver, podem se tornar ruidosos e prejudicar as previsões, como ocorreu com o parâmetro Aquecimento. Portanto, uma análise detalhada de todas as variáveis de entrada faz-se necessária. Em casos como o deste estudo, em que as variáveis de entrada fizerem parte de um conjunto de variáveis que descrevem uma cidade, deve-se fazer um balanço entre os valores extremos de todas as variáveis e verificar os impactos de escolher uma ou outra localidade para o conjunto de treinamento em função dessas variáveis.

6.3.4 Limites adotados para os parâmetros de entrada para o treinamento da rede

Como descrito no item 6.2.4, para este grupo adotaram-se três ações:

- (1) avaliação dos limites dos parâmetros de entrada nos conjuntos de treinamento e teste;
- (2) ajuste das cidades nos conjuntos; e
- (3) novo teste do agrupamento de Hemisférios.

6.3.4.1 Resultados da ação 1 – avaliação dos limites dos parâmetros de entrada nos conjuntos de treinamento e teste

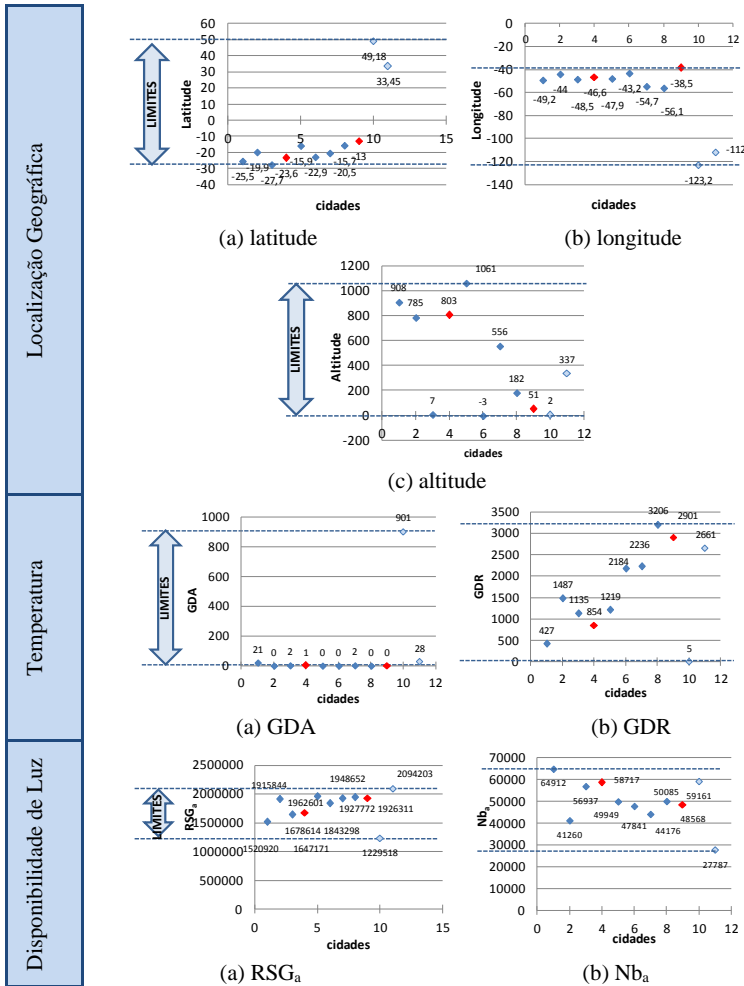
Neste item, todos os parâmetros de entrada foram considerados (G+T+S), sendo destacados os limites de cada um deles. A análise foi feita com base nas cidades do conjunto “nunca vistos”, São Paulo e Salvador.

Quando considerado apenas o Hemisfério Sul, a Latitude e a Longitude de Salvador são valores-limite (ver Figura 74a e b). Quanto à Altitude, ambas as cidades estão dentro dos limites; entretanto, Salvador está muito próxima do limite inferior (ver Figura 74c).

Para Graus Dia de Aquecimento (ver Figura 74d), o gráfico deixa clara a discrepância do valor de Vancouver, como comentado no conjunto anterior de ações. Tanto para Graus Dia de Aquecimento quanto para Graus Dia de Resfriamento, ambas as cidades estão dentro dos limites; entretanto, Salvador está próxima do limite inferior no primeiro caso (ver Figura 74d) e próxima do limite superior no segundo (ver Figura 74e).

Para Radiação Solar Global Acumulada e Índice de Nebulosidade Acumulada, quando considerado apenas o Hemisfério Sul, novamente a cidade de Salvador está próxima do limite superior (ver Figura 74f e g).

Figura 74 – Limites adotados para cada parâmetro de entrada



Legenda:

- ◆ 1 - ZB 1 - Curitiba
- ◆ 5 - ZB 4 - Brasília
- ◆ 9 - ZB 8 - Salvador (conjunto NV)
- ◆ 2 - ZB 2 - Belo Horizonte
- ◆ 6 - ZB 5/8 - Rio de Janeiro
- ◆ 10 - B - Vancouver
- ◆ 3 - ZB 3 - Florianópolis
- ◆ 7 - ZB 6 - Campo Grande
- ◆ 11 - ZB - Phoenix
- ◆ 4 - ZB 3 - São Paulo (conjunto NV)
- ◆ 8 - B 7 - Cuiabá

Onde:


- ◆ Conjunto de treinamento / validação (Hemisfério Sul)
- ◆ Conjunto de treinamento / validação (Hemisfério Norte)
- ◆ Conjunto "nunca vistos"

Fonte: Autor.

6.3.4.2 Resultados das ações 2 – ajuste das cidades nos conjuntos – e 3 – novo teste do agrupamento de Hemisférios

De acordo com o observado na ação (1), foi feito um ajuste nos limites da rede através da transferência do conjunto de dados da cidade de Salvador para o conjunto de treinamento e do conjunto de dados da cidade do Rio de Janeiro para o conjunto “nunca vistos”. Primeiramente, comparou-se o efeito da troca de cidades para a solução com Ambos os Hemisférios por ter sido a solução que apresentou menores erros no item 6.3.3. De acordo com a Figura 75, a troca das cidades melhorou o desempenho dos quatro parâmetros de saída para os três conjuntos (treino, “nunca vistos” e rede completa). A Iluminação foi a que apresentou maior redução de erros mediante a alteração, chegando a reduzir o EPAM em 11%, em termos absolutos, para o conjunto “nunca vistos”.

Figura 75 – Comparação entre os resultados antes e depois da troca de cidades para uma solução com Ambos os Hemisférios



Legenda:

■ G + T + S Ambos os Hemisférios ■ G + T + S Ambos os Hemisférios – trocando RJ por SAL


Os resultados foram então observados para as duas soluções de conjunto de treinamento – abordando Ambos os Hemisférios e somente o Hemisfério Sul – e comparados com os resultados do item 6.3.3, antes da troca das cidades. A Figura 76 ilustra os erros percentuais e absolutos médios do conjunto total de dados.

A troca de cidades não alterou o padrão de erros, observado no item 6.3.3, em que a exclusão das cidades do Hemisfério Norte resultou em melhora no treinamento e piora na generalização da rede.

Tanto para a solução que considera Ambos os Hemisférios quanto para a que considera o Hemisfério Sul, a troca das cidades foi benéfica, reduzindo os erros de previsão das redes. Entretanto, essa

diferença é mais expressiva para Iluminação no caso de Ambos os Hemisférios e para Resfriamento no caso do Hemisfério Sul, apresentando redução em torno de 45% e 20% em relação à solução anterior, respectivamente (ver Figura 76).

Figura 76 – Comparação entre os resultados antes e depois da troca de cidades para as soluções Hemisfério Sul e Ambos os Hemisférios para o conjunto total de dados



(a) EPAM para o conjunto total de dados

(b) EAM para o conjunto total de dados

Legenda:

- G + T + S Ambos os Hemisférios
 - G + T + S Hemisfério Sul
- G + T + S Ambos os Hemisférios – trocando RJ por SAL
 - G + T + S Hemisfério Sul – trocando RJ por SAL

É importante destacar que, quando considerado apenas o Hemisfério Sul, os parâmetros de entrada mais afetados pela troca de cidades foram Latitude, Longitude e Radiação Solar Global Acumulada, visto que, para esses dados, Salvador, que antes estava no conjunto “nunca vistos”, apresentou valores-limite ou próximos desses (ver Figura 74, p. 236). Essa observação confrontada com a redução do EPAM para Resfriamento pode indicar que esse parâmetro é mais afetado pelas referidas variáveis de entrada que os outros.

O ajuste de limites através da troca de cidades melhorou o desempenho da rede, em especial para a solução que considera Ambos os Hemisférios. Quando considerado apenas o Hemisfério Sul, a melhora para Iluminação não foi expressiva e para Aquecimento nem existiu. Logo, leva-se a concluir que esses parâmetros de saída são menos afetados pelas variáveis de entrada, que tiveram seus limites alterados com a retirada das cidades do Hemisfério Norte.

6.3.5 Variáveis para descrever características climáticas e de disponibilidade de luz

Como descrito no item 6.2.5, para este grupo adotaram-se duas ações:

- (1) substituição das variáveis térmicas; e
- (2) complementação das variáveis da disponibilidade de luz.

6.3.5.1 Resultados da ação 1 – substituição das variáveis térmicas

Nesta ação, as variáveis térmicas Graus Dia Aquecimento e Graus Dia Resfriamento, consideradas variáveis derivadas ou secundárias, foram substituídas por variáveis climáticas primárias. Classificaram-se como variáveis climáticas primárias as que podem se medidas. Os valores tabelados referem-se às médias do mês de janeiro (verão) e do mês de julho (inverno).

Com esse objetivo, escolheram-se as seguintes variáveis:

- Temperatura de bulbo seco (verão) – média (TBS_V);
- Temperatura de bulbo seco (inverno) – média (TBS_I);
- Umidade Relativa (verão) – média (UR_V);
- Umidade Relativa (inverno) – média (UR_I);
- Variação de temperatura (verão) – média (ΔT_V); e
- Variação de temperatura (inverno) – média (ΔT_I).

Para efeito de experimentação, nesta ação repetiu-se o teste do algoritmo Gradiente Descendente com o critério de parada: *até que 30% do conjunto de validação esteja dentro do limite de erro*. Os parâmetros da descrição do edifício, da Localização Geográfica e da Disponibilidade de Luz foram mantidos. Os valores adotados para cada novo parâmetro térmico podem ser vistos na Tabela 12.

Tabela 12 – Valores adotados para os novos parâmetros da descrição das características térmicas

CIDADES	CARACTERÍSTICAS TÉRMICAS					
	TBS _v [*] (°C)	TBS ₁ ^{**} (°C)	UR _v [*] (%)	UR ₁ ^{**} (%)	ΔT _v [*] (°C)	ΔT ₁ ^{**} (°C)
ZB 1 - Curitiba	20,9	13,6	83,9	83,8	8,7	9,7
ZB 2 - Belo Horizonte	24,0	18,9	73,4	68,6	7,9	12,4
ZB 3 - Florianópolis	24,4	17,1	84,7	85,1	7,1	6,8
ZB 3 - São Paulo (teste)	22,8	16,0	78,1	76,9	8,4	9,6
ZB 4 - Brasília	22,1	19,0	78,1	63,1	9,2	14,7
ZB 5/8 - Rio de Janeiro	26,6	20,8	77,0	79,1	6,4	6,4
ZB 6 - Campo Grande	25,8	21,0	77,3	65,9	10,0	11,0
ZB 7 - Cuiabá	27,5	23,4	75,8	63,5	8,1	13,0
ZB 8 - Salvador (teste)	27,2	24,3	76,7	78,6	3,8	2,9
Vancouver	17,0	3,2	86,6	76,2	5,0	9,2
Phoenix	35,6	13,0	36,9	29,9	11,5	12,1

Fonte: Adaptado de: Arquivos climáticos (US-DOE, 2011).

Notas:

* v: média do mês de verão (janeiro).


** v: média do mês de inverno (julho).

A Figura 77 apresenta os EPAMs separados por parâmetro de saída das RNAs, comparando-se o desempenho das redes do item anterior, ação (3): G+T+S para Ambos os Hemisférios, trocando Rio de Janeiro e Salvador com o desempenho dos novos parâmetros térmicos para Regularização Bayesiana e Gradiente Descendente. Comparando-se as duas soluções que utilizam Regularização Bayesiana, observou-se melhora no desempenho da rede para o conjunto de treinamento, mas piora no conjunto “nunca vistos” e no desempenho geral da rede (ver Figura 77a e b).

Já, ao confrontar a solução do item anterior na ação (3) com os novos parâmetros de entrada para Gradiente Descendente, o padrão de erros não foi claro, posto que, para o conjunto total de dados, o desempenho para Consumo Total e Resfriamento piorou, enquanto, para Aquecimento e Iluminação, melhorou (ver Figura 78a).

Por fim, comparando-se os resultados dos dois algoritmos para a nova configuração de parâmetro de entrada da descrição térmica, observou-se que os resultados de Gradiente Descendente são piores para Consumo Total e Resfriamento para o conjunto de treinamento (ver Figura 77a), mas melhores para todos os outros parâmetros de saída com conjunto “nunca vistos” (ver Figura 77b) e no desempenho geral da rede (ver Figura 78b).


Figura 77 – Comparação entre as soluções com diferentes variáveis térmicas, destacando-se o uso final para cada um dos três conjuntos da rede



Legenda:

- G + T + S Ambos os Hemisférios – trocando RJ por SAL
- G + T + S Ambos os Hemisférios – trocando RJ por SAL - Novos Parâmetros de Temperatura
- G + T + S Ambos os Hemisférios – trocando RJ por SAL - Novos Parâmetros de Temperatura – Gradiente Descendente 114.000 épocas

Figura 78 – Comparação entre as soluções com diferentes variáveis térmicas, destacando-se o uso final para todo o conjunto de dados da rede



Legenda:



Não é possível afirmar que os novos parâmetros de entrada da descrição térmica podem melhorar o desempenho da rede, visto que os testes com os dois algoritmos não superaram o desempenho da solução original (ver Figura 77 e Figura 78). Além disso, o acréscimo da quantidade de parâmetros de entrada aumentou a complexidade da rede e conseqüentemente o tempo de execução. Vale salientar que não foi feito teste de ajuste de quantidade de neurônios na camada oculta para essas propostas de rede.

6.3.5.2 Resultados da ação 2 – complementação das variáveis da disponibilidade de luz

A complementação de informações sobre disponibilidade de luz foi feita através da variável Iluminância Global Horizontal Acumulada. Para efeito de experimentação, nesta ação também se repetiu o teste do algoritmo Gradiente Descendente com o critério de parada: *até que 30% do conjunto de validação esteja dentro do limite de erro*. Os parâmetros da descrição do edifício, da Localização Geográfica e das Características Térmicas originais foram mantidos. Os valores adotados para cada parâmetro de entrada da rede podem ser vistos na Tabela 13.

Tabela 13 – Valores adotados para Iluminância Global Horizontal Acumulada

	DISPONIBILIDADE DE LUZ
CIDADES	IGH _a (lux n)
ZB 1 - Curitiba	28400
ZB 2 - Belo Horizonte	14700
ZB 3 - Florianópolis	16600
ZB 3 - São Paulo (teste)	47600
ZB 4 - Brasília	42000
ZB 5/8 - Rio de Janeiro	17700
ZB 6 - Campo Grande	21900
ZB 7 - Cuiabá	25100
ZB 8 - Salvador (teste)	12700
ZB - Vancouver	800
ZB - Phoenix	15800

Fonte: Adaptado de: Arquivos climáticos (US-DOE, 2011).


Analogamente à ação anterior, a Figura 79 apresenta os EPAMs separados por parâmetro de saída das RNAs, comparando-se o desempenho das redes do item 6.3.4, ação (3): G+T+S para Ambos os Hemisférios, trocando Rio de Janeiro e Salvador com o desempenho dos novos parâmetros térmicos para Regularização Bayesiana e Gradiente Descendente. Comparando-se as duas soluções que utilizam Regularização Bayesiana, observou-se melhora no desempenho da rede para o conjunto de treinamento, mas piora no conjunto “nunca vistos” e no desempenho geral da rede (ver Figura 79a e b).

Novamente, confrontando a solução do item 6.3.4, ação (3), com os novos parâmetros de entrada para Gradiente Descendente, notou-se diminuição do desempenho do conjunto de treinamento para Consumo Total e Resfriamento (ver Figura 79a); entretanto, para os conjuntos “nunca vistos” e no desempenho do conjunto total de dados, todos os parâmetros de saída apresentaram melhora do desempenho (ver Figura 79b e c).

Por fim, comparando-se os resultados dos dois algoritmos para a nova configuração de parâmetro de entrada da descrição térmica, observou-se que os resultados de Gradiente Descendente apresentaram erros menores que as duas configurações de rede que usaram a Regularização Bayesiana para todos os parâmetros de saída das redes (ver Figura 80a e b).

A Figura 79c e a Figura 80 mostram que, para o resultado global da rede, a adição da Iluminância Horizontal Global Acumulada aumentou os erros da rede em comparação ao mesmo algoritmo da configuração original (ver item 6.3.4, ação (3)). Por outro lado, ao comparar as duas soluções que incluíram o novo parâmetro de entrada, a solução com Gradiente Descendente mostrou melhora no desempenho (ver Figura 80).


Figura 79 – Comparação entre as soluções com diferentes variáveis da disponibilidade de luz, destacando-se o uso final para cada um dos três conjuntos da rede



Legenda:

- G + T + S Ambos os Hemisférios – trocando RJ por SAL
- G + T + S Ambos os Hemisférios – trocando RJ por SAL – Novos Parâmetros de Disponibilidade de Luz
- G + T + S Ambos os Hemisférios – trocando RJ por SAL – Novos Parâmetros de Disponibilidade de Luz – Gradiente Descendente 114.000 épocas

Figura 80 – Comparação entre as soluções com diferentes variáveis da disponibilidade de luz, destacando-se o uso final para todo o conjunto de dados da rede



Legenda:

■ Cons. Total ■ Aquec. ■ Resfr. ■ Ilum.


Da mesma forma que para os novos parâmetros térmicos, o benefício da inclusão do parâmetro Iluminância Horizontal Global Acumulada não foi conclusivo, visto que os resultados foram conflitantes e justamente o mesmo algoritmo da solução original apresentou piora no desempenho. Vale salientar que não foi feito teste de ajuste de quantidade de neurônios na camada oculta para essas propostas de rede.

6.3.6 Validação do método de teste de metamodelos baseados em simulações energéticas paramétricas

A Figura 81 apresenta os EPAMs separados por parâmetro de saída das RNAs, comparando-se o desempenho das redes do item 6.3.4, ação (3): G+T+S para Ambos os Hemisférios, trocando Rio de Janeiro por Salvador testadas com o conjunto “nunca vistos” e com a abordagem de teste da literatura. A seleção randômica do conjunto de teste segundo abordagem da literatura reduziu sutilmente o desempenho do conjunto de treinamento, mas, como os erros desse conjunto já eram baixos, essa alteração não foi significativa (menor que 0,2% em termos absolutos, com exceção do Aquecimento) (ver Figura 81a). Por outro lado, a redução dos erros no conjunto de teste, quando comparada à solução conjunto “nunca vistos”, foi extremamente significativa, com

redução de 18% no EPAM em termos absolutos para Resfriamento (ver Figura 81b). De acordo com a Figura 81c, quando a rede é considerada de forma global, o EPAM dos parâmetros de saída (desconsiderando Aquecimento) não ultrapassa 2,5%. Essa redução faz com que o erro de todos os parâmetros de saída somados fique abaixo de 5% (ver Figura 82), valor, por muitas vezes, considerado alvo na bibliografia.

Figura 81 – Comparação entre o desempenho da rede testada conforme método da literatura e conjunto “nunca vistos”, destacando-se o uso final para cada um dos três conjuntos da rede




Legenda:

- G + T + S Ambos os Hemisférios – trocando RJ por SAL (teste conj. NV – nunca vistos)
- G + T + S Ambos os Hemisférios – trocando RJ por SAL (teste abordagem literatura: randômico 80-20)

Observando a Figura 82, que ilustra os erros do conjunto total de dados (treinamento + teste) para todos os parâmetros de saída sobrepostos, pode-se perceber que a redução dos erros da abordagem “nunca vistos” para a abordagem do conjunto teste da literatura chega a 50%. Isso porque, para a abordagem do conjunto “nunca vistos” adotada neste trabalho e mais conservadora, o EPAM chega a 10%, enquanto, para a abordagem da literatura, não ultrapassa 5%.

Figura 82 – Comparação entre o desempenho da rede testada conforme método da literatura e conjunto “nunca vistos”, destacando-se o uso final para todo o conjunto de dados da rede



Legenda:

Esta avaliação foi considerada importante, visto que a utilização apenas da abordagem da literatura pode mascarar o desempenho do modelo para casos nunca vistos, mas que estão dentro dos limites de exemplos apresentados à rede. Se a diferença de 50% de erro entre os dois métodos refere-se a apenas 5% em valor absoluto de EPAM para o conjunto total de dados, para o conjunto de teste ela é muito maior (por exemplo, 18% para Resfriamento). Sendo assim, a combinação dos dois métodos permite dizer que a rede tem potencial de prever resultados com erros inferiores a 5% devido à avaliação de sua convergência (treinamento) e de generalização (abordagem da literatura), porém com a limitação de errar em até 20% dependendo do caso nunca visto e do padrão de saída por uso final (conjunto “nunca vistos”).

6.4 CONSIDERAÇÕES FINAIS SOBRE O CAPÍTULO

Neste capítulo foram apresentados os detalhes do método e os resultados para a investigação sistemática sobre as particularidades das variáveis do contexto do edifício com relação às redes neurais artificiais. Para a organização das etapas da investigação sistemática, os resultados foram apresentados em grupos de ações realizadas. Primeiramente, definiram-se as variáveis-chave que compuseram a investigação. Então, foram definidos os cinco conjuntos de ações que visaram responder às perguntas de pesquisa listadas no início deste capítulo e, conseqüentemente, à pergunta estruturante do capítulo. Os resultados desse conjunto de ações permitiram responder às perguntas que são aqui apresentadas de forma sintética.

Qual o impacto de diferentes arquiteturas da rede neural para modelar características do contexto do edifício? (pergunta 1)

A variação do número de neurônios foi mais expressiva em termos de erros que a variação de algoritmos. Entretanto, sob o aspecto do tempo de execução da rede, apesar de a quantidade de neurônios ser importante, a definição do algoritmo é ainda mais.

Qual é o efeito do agrupamento de parâmetros de entrada do contexto do edifício de diferentes categorias? (pergunta 2)

O agrupamento de parâmetros é extremamente significativo, pois diferentes grupos apresentam influências diferentes no desempenho da rede. Os parâmetros da Localização Geográfica foram os de maior importância. A combinação dos diferentes grupos também apresentou diferentes padrões de erro. Os efeitos de cada agrupamento são percebidos diferentemente pelos parâmetros de saída da rede para o conjunto de teste “nunca vistos”.

Qual é o efeito de se agrupar localidade de condições geográficas significativamente distintas, como diferentes Hemisférios separados pela Linha do Equador, apresentando as orientações significados opostos em termos de insolação e radiação? (pergunta 3)

O agrupamento de variáveis de diferentes Hemisférios em geral mostrou-se mais eficiente do que a consideração somente do Hemisfério Sul, visto que resultou em redes com maior poder de generalização. Entretanto, variáveis muito discrepantes, como o caso dos valores de Graus Dia de Aquecimento para Vancouver, podem prejudicar a convergência da rede para os padrões de saída mais influenciados por essa variável, no caso o Aquecimento. Os efeitos das alterações dos agrupamentos por Hemisfério não são percebidos da mesma forma pelos parâmetros de saída.

Como diferentes tipos de variáveis-chave podem descrever os parâmetros térmicos do clima? (pergunta 4)

No caso deste trabalho, utilizaram-se duas abordagens de parâmetros: parâmetros derivados (definidos em função de outros) e parâmetros primários (que podem ser medidos). A substituição dos parâmetros derivados pelos primários para descrever as características térmicas da edificação mostrou-se inadequada. De acordo com os testes realizados, para a modelagem de parâmetros do consumo energético, os mais indicados são Graus Dia de Aquecimento e Graus Dia de Resfriamento. Esses parâmetros foram escolhidos porque os modelos

estudados são condicionados. Para outras abordagens de rede, os parâmetros ditos primários podem ser adequados.

Como diferentes tipos de variáveis-chave podem descrever as condições de disponibilidade de luz para diferentes localidades? (pergunta 5)

Para a descrição da disponibilidade de luz, utilizaram-se informações sobre radiação, nebulosidade e iluminância, todas com abordagem acumulativa. Não foi possível afirmar que a adição da terceira informação foi útil para a rede, visto que os resultados foram divergentes. Logo, aumentar a quantidade de parâmetros de descrição não necessariamente irá melhorar o modelo.

7. INVESTIGAÇÃO SISTEMÁTICA DAS POTENCIALIDADES E DAS LIMITAÇÕES DAS RNAs – DESEMPENHO DO EDIFÍCIO

Este capítulo descreve a investigação sistemática da metamodelagem das principais variáveis da descrição do desempenho do edifício sob o enfoque do trabalho. Da mesma forma que nos capítulos anteriores, serão apresentados o resumo da estrutura do capítulo relacionando as perguntas de pesquisa, as ações e os resultados; o esquema da aplicação da etapa 3 do método geral; e a sequência de ações realizadas para responder às perguntas. Os resultados são agrupados conforme as respectivas ações realizadas para obtê-los.

7.1 INTRODUÇÃO

Como premissa para as investigações conduzidas neste capítulo, optou-se por observar as variáveis-chave de energia que vêm sendo usadas no trabalho juntamente com as variáveis de suficiência de iluminação. As variáveis de suficiência foram escolhidas por serem mais facilmente obtidas através de programa de simulação computacional. Como o foco deste capítulo foi a abordagem das variáveis de desempenho, decidiu-se por combinar todas as variáveis-chave da descrição do edifício que influenciam a iluminação natural a fim de testar os limites do modelo quanto à predição do desempenho para diferentes variáveis. Quanto à simulação, optou-se por utilizar a simulação integrada, que oferece resultados mais precisos quanto ao fenômeno da iluminação, já que variáveis de desempenho de iluminação serão avaliadas. Além disso, considerando-se combinações paramétricas mais complexas da descrição do edifício, a precisão na modelagem do fenômeno torna-se mais relevante. Como não seria possível simular todas as combinações dos parâmetros da descrição do edifício, utilizou-se a técnica de amostragem Hipercubo Latino para definir o conjunto de casos a ser usado no treinamento das redes neurais. Quanto às redes neurais, procurou-se seguir o padrão de avaliação de algoritmo e o número de neurônios adotados nos capítulos anteriores.

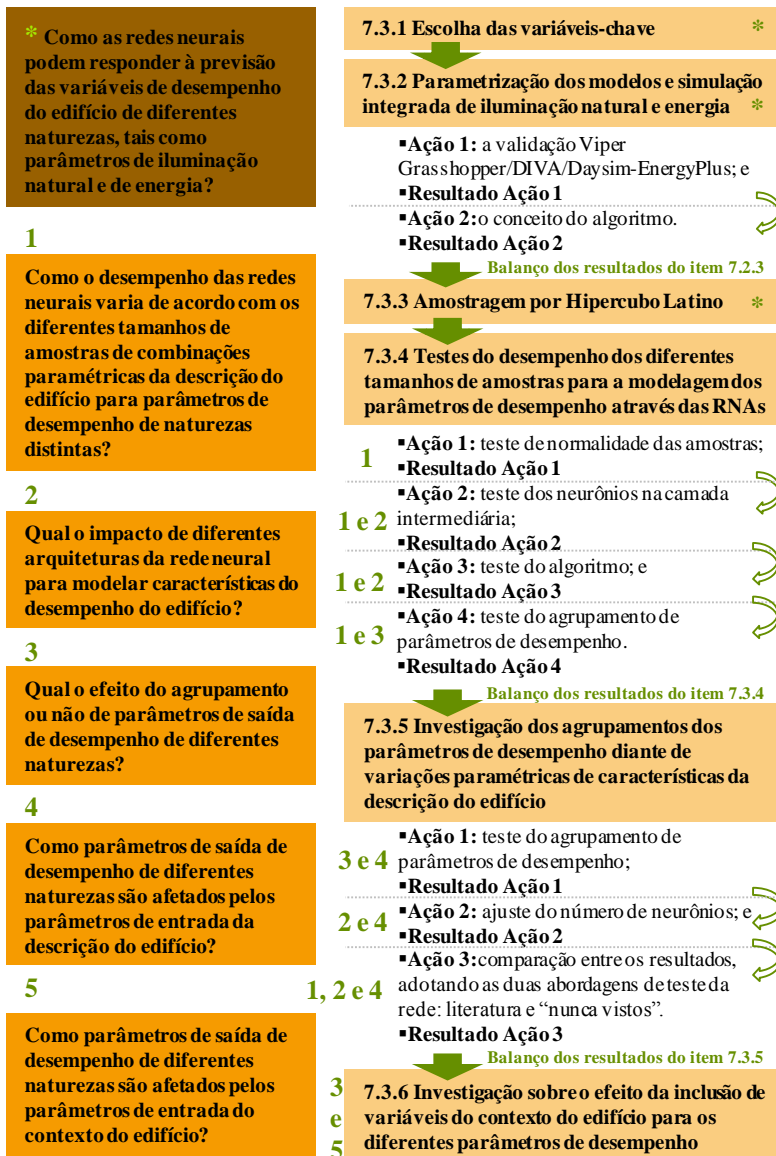
7.2 DETALHAMENTO DO MÉTODO

Da mesma forma que nos Capítulos 5 e 6, a Figura 83 traz a principal pergunta de pesquisa que direcionou a proposição deste capítulo, conforme apresentada no capítulo do método geral, item 3.2, p.

105. Essa pergunta foi destacada no quadro marrom, codificada com um asterisco, e originou as cinco outras perguntas. A relação entre as perguntas, as ações e os resultados foi representada graficamente da mesma forma como descrito no item 5.2, p. 147.

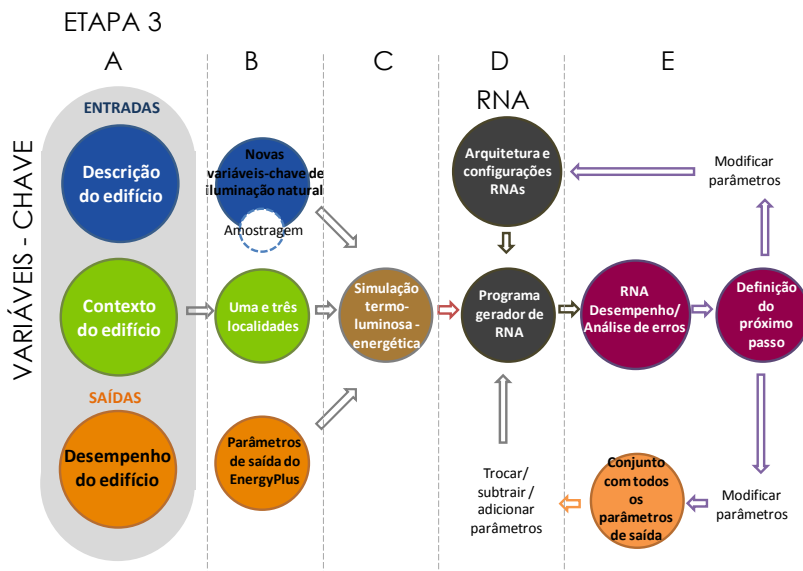
Figura 83 – Resumo do processo da avaliação sistemática: desempenho do edifício

DESEMPENHO DO EDIFÍCIO



Para responder às perguntas de pesquisa, adotaram-se as ações metodológicas apresentadas na Figura 84. Primeiramente, definiram-se os grupos das variáveis-chave que seriam trabalhadas, nesse caso os três grupos com enfoque no desempenho do edifício. As variáveis da descrição e do contexto do edifício foram definidas e variadas de forma secundária, apenas quando necessário para melhor observar algum efeito nas variáveis de desempenho do edifício. Essa abordagem foi adotada de forma a reduzir as interferências nas análises.

Figura 84 – Aplicação da etapa metodológica 3 – desempenho do edifício



Fonte: Autor.

Como o conjunto de variáveis-chave e seus valores adotados neste capítulo geraria um conjunto de dados que inviabilizaria as simulações, utilizou-se a técnica Hipercubo Latino para amostrar as variáveis de descrição do edifício. A geração dos dados para o treinamento das redes foi feita através de simulações integradas paramétricas, utilizando-se Grasshopper e DIVA.

Para a operacionalização da aplicação das redes neurais, utilizou-se o programa EasyNN-plus em conjunto com o programa MATLAB, da mesma forma que no Capítulo 6. Os efeitos das perturbações nas redes neurais foram avaliados através de análise dos erros, da mesma

forma que nos capítulos anteriores. O número de redes para cada caso variou entre 3 e 10 conforme o tempo de processamento.

Dois grupos metodológicos foram estabelecidos, tendo sido propostos para cada um deles conjuntos de ações para responder às perguntas, como descrito a seguir.

a) Grupo 1: Operacionalização:

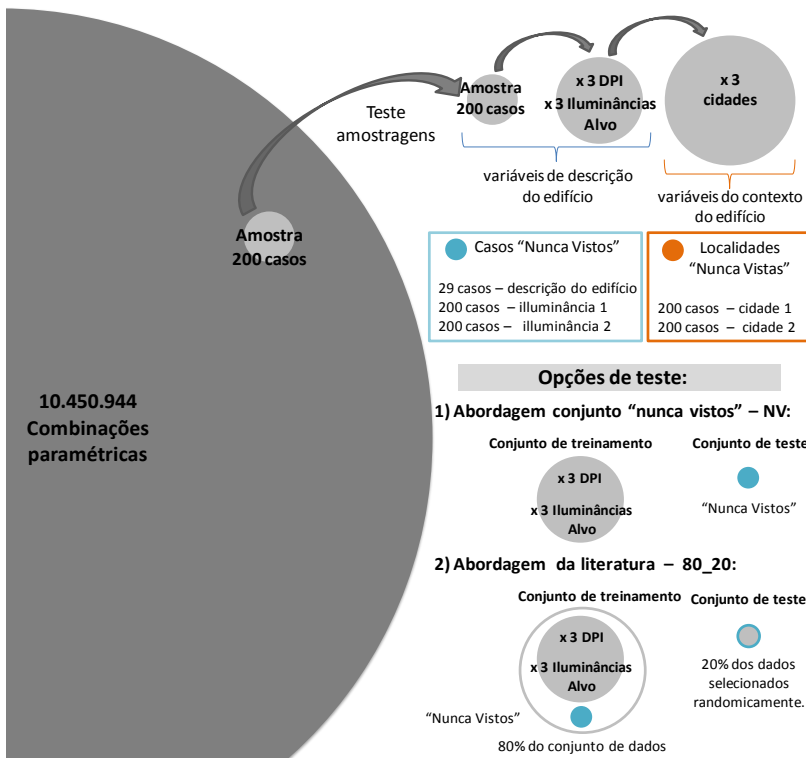
- Escolha das variáveis-chave a serem parametrizadas.
- Parametrização dos modelos e simulação integrada de iluminação natural e energia.
- Amostragem por Hipercubo Latino.
- Testes do desempenho dos diferentes tamanhos de amostras para a modelagem dos parâmetros de desempenho através das RNAs.

b) Grupo 2: Testes de parâmetros de saída de desempenho:

- Investigação dos agrupamentos das variáveis de desempenho diante de alterações paramétricas de variáveis da descrição do edifício.
- Investigação sobre o efeito da inclusão de variáveis do contexto do edifício para as diferentes variáveis de desempenho.

As etapas descritas anteriormente são resumidas no esquema da Figura 85.

Figura 85 – Esquema das etapas da investigação conforme amostragem e seleção de parâmetros para as análises



Fonte: Autor.

Os detalhes metodológicos da escolha das variáveis-chave e das ações realizadas em cada um dos cinco grupos de ações listados para operacionalização e testes dos parâmetros de desempenho são apresentados nos subitens a seguir (item 7.2.1 ao 7.2.6).

7.2.1 Escolha das variáveis-chave

Da mesma forma que nos capítulos anteriores, determinaram-se quais os grupos da Figura 3, p. 61, faziam parte do desempenho do edifício. Dentro desses grupos, elencaram-se as variáveis escolhidas. Adicionalmente, selecionaram-se as variáveis dos seis grupos do segundo membro da equação da mesma figura, referente a parâmetros determinantes para o desempenho da iluminação natural. Com isso,

buscou-se avaliar os parâmetros de desempenho diante de efeitos de pelo menos uma variável de cada grupo, referente aos aspectos influentes sobre a iluminação natural. Com o objetivo de oferecer um mínimo de informação necessária para o aprendizado da rede e evitar a necessidade de extrapolação, para cada parâmetro foram adotados no mínimo três variações, sendo duas delas valores extremos. A escolha das variáveis-chave também considerou a proposição do conceito do algoritmo do Grasshopper, apresentado no item 3.4.1, p. 107, a fim de permitir a sua aplicabilidade para diversas abordagens.

7.2.2 Parametrização dos modelos e simulação integrada de iluminação natural e energia

Para viabilizar a simulação de diferentes amostras dentre as combinações paramétricas das variáveis-chave escolhidas, foi proposto um algoritmo de parametrização no qual toda a modelagem foi pré-preparada. Para isso, utilizou-se o Grasshopper (RUTTEN, 2011), *plug-in* do programa Rhinoceros de modelagem tridimensional (MCNEEL; ASSOCIATES, 2014). O algoritmo foi utilizado para ler os arquivos *.csv resultantes das amostragens, realizar as simulações integradas e gravar os seus resultados. Mais informações sobre a programação do algoritmo podem ser obtidas em Felipe et al. (2015).

O Grasshopper oferece dois componentes para a simulação dos desempenhos térmico e luminoso da edificação (simulação integrada), ambos baseados nos conceitos do *plug-in* DIVA (JAKUBIEC; REINHART, 2011). O componente térmico, objeto Viper, que executa o EnergyPlus, e o componente de desempenho de iluminação natural, que executa o Daysim. Os parâmetros de entrada do Radiance adotados para a simulação de iluminação natural podem ser observados na Tabela 14.

Tabela 14 – Parâmetros do Radiance para a simulação de iluminação natural do algoritmo de parametrização

Inter-reflexões difusas do ambiente	Divisão do ambiente	Amostragem do ambiente	Precisão do ambiente	Resolução do ambiente	Limiar direto	Amostragem direta
2	1000	20	0,1	300	0	0

Fonte: Adaptado de: Reinhart (2012).

O objeto Viper baseia as simulações do EnergyPlus em arquivos *.idf padrão semiestruturados para uma zona térmica, que são usados

como base para simplificar a simulação para o usuário. Como base de cálculo de carga térmica, utiliza a classe *Ideal Loads Air System*, que simula um condicionador de ar ideal considerando o sistema de forma simplificada. Assim, o usuário não pode alterar determinados parâmetros pela interface. Como se optou por seguir com algumas configurações do EnergyPlus que estavam sendo utilizadas nos capítulos anteriores, alterações nos arquivos *.idf base do programa se fizeram necessárias. Além disso, os casos que foram utilizados para testar a rede (conjunto “nunca vistos”) foram simulados diretamente no DIVA devido ao aumento na complexidade do algoritmo para inclui-los na programação. O DIVA também possui um arquivo *.idf padrão ao qual são adicionadas as informações que o usuário insere na interface e no qual é montado o arquivo de simulação. Os arquivos padrão/base dos dois programas apresentam algumas diferenças; logo, julgou-se prudente alinhá-los de forma a garantir que os resultados que foram usados para treinar e testar as redes neurais estivessem coerentes. Para tanto, procedeu-se a uma validação das simulações integradas feitas para o item 4.3.3 do Capítulo 4, p. 137, usando Daysim-EnergyPlus, reproduzindo-a através do DIVA e, posteriormente, através do Grasshopper.

O desenvolvimento do algoritmo baseou-se no conceito ilustrado na Figura 13, p. 110. A estrutura desse algoritmo foi proposta de forma a gerar uma ferramenta que pudesse ser aplicada em diversas amostragens diferentes sem necessitar de reprogramação, além de permitir a fácil inserção de novos valores para as variáveis-chave incluídas, propondo-se, assim, uma ferramenta de múltiplas aplicações.

7.2.3 Amostragem por Hipercubo Latino

A amostragem por Hipercubo Latino foi realizada no programa MATLAB, utilizando como base a função *lhsdesign* (n,p) (THE MATHWORKS INC, 2014). A função retorna uma matriz n por p , contendo uma amostra por Hipercubo Latino de n valores de cada um dos parâmetros (p). Para cada coluna da matriz, os n valores são distribuídos aleatoriamente para cada intervalo $(0,1/n)$, $(1/n, 2/n)$..., $(1-1/n, 1)$ e permutados aleatoriamente.

A intenção deste trabalho foi observar as relações entre as variáveis-chave, e não modelar a frequência de ocorrência dos valores dessas variáveis na realidade (por exemplo, PAF ou tipo de vidro mais usual); sendo assim, a distribuição adotada para todas as variáveis de entrada foi a uniforme, considerando-se que todos os valores adotados

para cada entrada apresentam a mesma frequência de ocorrência. Dessa forma, para os testes nas redes neurais, todos os parâmetros são avaliados da mesma forma.

A definição do tamanho da amostra não possui regra clara, sendo influenciada pela quantidade de dados de entrada e pela complexidade dos casos (MELO, 2012); acrescenta-se ainda a complexidade do fenômeno a ser modelado. Para uma estimativa inicial do número de casos a serem amostrados, buscou-se verificar se o conjunto de variáveis tratava de uma distribuição normal. Como o conjunto de dados ainda seria gerado, utilizou-se o conjunto de Didoné (2009), apresentado no item 4.2.1, p. 127, do Capítulo 4. Apesar de o conjunto de dados não abranger todas as variáveis-chave que foram consideradas neste trabalho, julgou-se suficiente para uma primeira verificação por tratar-se de uma proposta semelhante e que objetivou modelar os efeitos da iluminação natural no consumo energético. Para o teste da distribuição de probabilidades, adotou-se o teste Kolmogorov-Smirnov. Esse teste se baseia na verificação da função de distribuição acumulada, assumida para os dados da amostra em relação a dado nível de significância, a fim de comprovar ou descartar a hipótese de normalidade (WEISSTEIN, 2014).

Como alternativa para a definição desses diferentes números de amostras, avaliou-se a quantidade total de amostras proporcionalmente a outros estudos semelhantes da bibliografia. Melo (2012) utilizou redes neurais artificiais para modelar o consumo energético de edificações baseadas em dados simulados no programa EnergyPlus. Nesse estudo, um conjunto de interações entre 12 parâmetros físicos da edificação, cuja distribuição foi considerada uniforme, foi amostrado em 200 casos por meio da mesma técnica. Segundo a autora, esse valor foi adotado por experimentação. Se todas as combinações dos valores escolhidos para cada parâmetro tivessem sido feitas, o conjunto resultaria em 4.572.288 de casos. Ainda abordando a modelagem do aspecto térmico com base em simulação computacional por meio de outras técnicas que não a RNA, Silva e Ghisi (2012) utilizaram o Hipercubo Latino para amostrar combinações entre 12 parâmetros físicos da edificação para simulação termoenergética. Os autores utilizaram 500 casos para cada grupo de verificações. Capozzoli, Mechri e Corrado (2009) utilizaram 6 parâmetros e amostraram 100 casos. Hopfe et al. (2007) amostraram 200 interações referentes a 26 parâmetros para comparar programas de simulação de desempenho termoenergético da edificação. Lomas e Eppel (1992 apud Macdonald; Strachan, 2001) recomendam amostras de 60 a 80 casos do método Monte Carlo, do qual é derivado o Hipercubo

Latino, para simulações térmicas do edifício. Quanto à consideração da iluminação natural sob o aspecto energético, Shen e Tzempelikos (2012) utilizaram a AHL para obter interações entre 7 parâmetros da edificação, com enfoque nos elementos da fachada, por meio de amostras de 140 casos.

Outra referência utilizada para dimensionar o tamanho da amostra foi a de Bartlett, Kotrlik e Higgins (2001), que sugerem que a amostra seja em torno de 10 vezes o número de parâmetros envolvidos no caso de análise de regressão multivariada envolvendo variáveis contínuas e cinco vezes no caso de variáveis discretas. Como a maioria das variáveis abordadas é contínua, adotou-se esta opção para a estimativa do número de casos.

Com base nesses estudos, definiram-se três conjuntos de amostras, abordados no item 7.3.3, p. 276. Vale salientar que este estudo contempla parâmetros de desempenho de iluminação natural e energia, ao passo que a maioria dos estudos anteriores foi realizada apenas considerando parâmetros de desempenho de energia. Logo, caso a maior amostra ainda não resultasse em erro aceitável, aumentar-se-ia o tamanho das amostras. Como resultado das amostragens, o programa MATLAB gerou planilhas (*.csv) com os parâmetros de cada caso amostrado, utilizadas como dado de entrada para o algoritmo de parametrização.

7.2.4 Testes do desempenho dos diferentes tamanhos de amostras para a modelagem dos parâmetros de desempenho através das RNAs

Para os testes de normalidade das três amostragens resultantes do item 7.2.3, foi realizado o teste Kolmogorov-Smirnov, aplicado aos valores reais e aos valores transformados em escala logarítmica. Adicionalmente, foram gerados histogramas de frequência de ocorrência para todos os parâmetros de saída das simulações para uma melhor análise das distribuições amostrais.

Para as redes neurais utilizadas neste capítulo, a camada de entrada é composta de parâmetros da descrição do edifício e do contexto da edificação (quando aplicável); e a camada de saída, dos parâmetros de desempenho do edifício. Para a geração dos metamodelos para os testes do tamanho das amostras, primeiramente foi experimentado o número de neurônios na camada interna da rede. Iniciou-se pela aplicação da heurística, descrita na Equação 8, p. 83, aumentando-se progressivamente a quantidade de neurônios e, depois de definida a

quantidade que proporcionou o melhor desempenho da rede, partiu-se para a definição de um algoritmo de aprendizagem e, por fim, para a disposição dos parâmetros de saída. Os testes de quantidade de neurônios na camada interna dos algoritmo de aprendizagem foram realizados apenas para o maior conjunto amostrado.

Para todos os testes, foram simuladas três redes neurais idênticas, visando garantir que o resultado fosse representativo daquela configuração de rede. As arquiteturas de rede foram separadas em parâmetros de saída de iluminação natural, de energia e ambos na mesma rede. Ou seja, foram geradas três configurações de redes neurais a fim de averiguar a possibilidade de uma rede para modelar satisfatoriamente os resultados de iluminação natural e energia.

Nesta etapa, a rede não foi testada com o conjunto “nunca vistos”. Os erros da rede foram avaliados com base em todo o conjunto utilizado para treinamento e depois para teste. Adotou-se essa abordagem para a comparação das amostras para não separar um percentual do conjunto para testes ou usar casos “nunca vistos” que poderiam, em seu caso específico, ser mais bem representados por uma amostra que por outra.

7.2.5 Investigação dos agrupamentos dos parâmetros de desempenho diante de variações paramétricas de variáveis da descrição do edifício

Para esta etapa, os conjuntos amostrados que tinham sido simulados para apenas um valor de Iluminância-alvo e um de Densidade de Potência Instalada (DPI) foram replicados para outros dois valores de Iluminâncias-alvo e outros dois de DPIs.

Para a investigação dos parâmetros de desempenho do edifício, primeiramente foi gerada uma rede com os parâmetros de iluminação natural e energia, mas acrescentados os dois novos parâmetros de entrada: iluminância-alvo e DPI. Em um segundo momento, os parâmetros de saída de energia e iluminação natural foram separados em redes diferentes. Em ambos os casos, adicionou-se um parâmetro de saída derivado do consumo com iluminação artificial ao considerar a iluminação natural, o qual neste trabalho será chamado de Percentual de Densidade de Potência em Uso (DPU). Adicionalmente, testaram-se redes com este parâmetro isoladamente. Mesmo fixando os parâmetros de entrada, o número de neurônios na última camada variou conforme o agrupamento avaliado, alterando a complexidade da rede. Assim, adotou-se para a camada interna a quantidade de neurônios referente ao

produto do número de neurônios na camada de entrada pela camada de saída. No caso da rede só com DPU como parâmetro de saída, essa experimentação coincidiu com o número de neurônios indicado pelo EasyNN-plus.

Visando verificar a influência do número de neurônios na camada oculta para a rede com parâmetros de saída de iluminação natural e energia, mas com os dois novos parâmetros de entrada, a rede foi testada com mais duas configurações: utilizando 100 neurônios (melhor solução para o treinamento da etapa anterior) e aplicando a heurística descrita na Equação 8, p. 83. Adicionalmente, testaram-se as redes com apenas o parâmetro DPU com a mesma heurística.

Finalmente, foram testadas redes apenas com o parâmetro de saída DPU para as duas abordagens de divisão de conjunto de teste: o conjunto “nunca vistos” e o método da literatura, no qual o conjunto de dados é particionado em percentuais para treinamento e teste (abordagem utilizada no item 6.2.6, p. 219). Para os novos testes, foi utilizada a mesma configuração da camada de saída com parâmetros de energia e iluminação em uma mesma rede descrita no item anterior. Testaram-se novas variações do número de neurônios, primeiramente utilizando a ferramenta do EasyNN-plus e depois aplicando a heurística descrita na Equação 8, p. 83.

Para viabilizar a observação de todos os parâmetros de desempenho em uma mesma escala e em um mesmo gráfico, os erros quadráticos médios dos 11 parâmetros de saída foram normalizados por meio da Equação 19, p.120.

7.2.6 Investigação sobre o efeito da inclusão de variáveis do contexto do edifício para os diferentes parâmetros de desempenho

Até esta etapa, as simulações tinham sido realizadas apenas para uma cidade: Florianópolis. Para testar os parâmetros do contexto do edifício, acrescentaram-se mais duas cidades ao treinamento da rede: Belém e Brasília. A escolha das cidades deu-se em função da latitude; entretanto, consideraram-se também as variações das outras características climáticas. Assim, incluíram-se nas redes neurais parâmetros de entrada da descrição do contexto do edifício.

Esse novo conjunto foi testado com redes, combinando parâmetros de energia, iluminação e DPU e apenas o parâmetro DPU para duas configurações de neurônios, escolhidos da mesma forma que no item anterior. Como essas configurações de rede possuíam muitos

parâmetros de entrada e um conjunto grande de exemplos para o treinamento, os testes com parâmetros de saída de iluminação, energia e DPU foram feitos considerando-se apenas dois parâmetros de iluminação e três de energia.

O desempenho da rede foi avaliado utilizando-se o conjunto “nunca vistos”. A abordagem de erros normalizados por meio da Equação 19, p.120, também foi utilizada neste subitem.

7.3 RESULTADOS


Primeiramente, são apresentados os resultados da escolha das variáveis-chave e, na sequência, os resultados alocados nos cinco grupos, descritos do item 7.2.3 ao 7.2.6.

7.3.1 Escolha das variáveis-chave

A escolha das variáveis novamente foi pautada no quadro de Heshong (2011), conforme Figura 3, p. 61, considerando-se ao menos uma variável de cada categoria (A a F). Isso permitiu que a avaliação dos parâmetros de desempenho, segundo o uso de RNA, abrangesse as principais questões que influenciam a iluminação natural; entretanto, limitando-se às capacidades de descrição inerentes às variáveis adotadas dentro de cada categoria.

A Figura 86 ilustra as variáveis-chave parametrizadas para uma zona termoluminosa. Além dessas variáveis, ainda foram consideradas a localidade, a densidade de potência instalada de iluminação e a iluminância-alvo, destacadas em alaranjado na mesma figura. A Tabela 15 exibe os valores das variáveis-chave adotadas, que, por vezes, são agrupadas para identificar um elemento construtivo (por exemplo, vidro) (SHEN; TZEMPELIKOS, 2012) ou um conceito construtivo (por exemplo, geometria). Assim, considerou-se que foram trabalhadas 18 variáveis-chave da descrição do edifício, agrupadas em 11 parâmetros.

Figura 86 – Modelo da zona termoluminosa e parâmetros variados



Fonte: Adaptado de: Felipe et al. (2015).

Tabela 15 – Variáveis selecionadas para parametrização, suas respectivas quantidades e valores adotados

(continua)			
	Variável/Unidade	Nº de observações	Variações/ Unidade
Não amostradas	*Localidades (Latitude, Longitude, Altitude, HDD, CDD, GSL _a , CI _a)	3	Florianópolis (Latitude 27°), Brasília (Latitude 15°) e Belém (Latitude 1°).
	Densidade de potência em iluminação – DPI (W/m ²)	3	2, 12 e 20 W/m ²
	Iluminância-alvo (lux)	3	100, 300 e 500 lux
1**	Refletância das superfícies (%)	3	Combinações teto – parede e piso (%): alta (80-80-20), média (80-40-20) e baixa (40-40-20).
2**	Percentual de abertura: Fachada – PAF (%) Cobertura – PAZ (%)	7	PAF 20%; PAF 50%; PAF 80%; PAZ 2%, abertura concentrada; PAZ 2%, abertura distribuída; PAZ 40%, abertura concentrada; e PAZ 40%, abertura única.
3**	Proteções solares (fixas e externas) Horizontais – AVS (°) Verticais – AHS (°)	8	Combinações (0°; AVS 30°; AVS 45°; AVS 60°; AHS30°; AHS 45°; AHS 60°; AVS 45°+ AHS 45°)
4*	Vidros: T _{vis} (%) FS (%)	6	T _{vis} : 0,88; 0,43; 0,05; 0,5; 0,77; 0,46 FS: 0,819; 0,602; 0,232; 0,45; 0,468; 0,351
5	Orientações (°)	8	N, S, L O, NE, NO, SE, S
6**	Densidade de carga interna – DCI ocupação (W/m ² .pessoa) equipamentos (W/m ² .equipamento)	3	Ocupação + Equipamentos: 12, 21, 36 W/m ²
7**	Propriedades térmicas dos fechamentos opacos: Absortância (%) e transmitância (W/(m ² K)) de paredes e coberturas	3	Adiabático, pouca troca, média troca (absortância constante)

Fonte: Autor

Tabela 15 – Variáveis selecionadas para parametrização, suas respectivas quantidades e valores adotados

(conclusão)			
	Variável/Unidade	Nº de observações	Variações/ Unidade
8**	Geometria – proporções (K ²³) Largura (m) Profundidade (m) Altura (m)	3	Proporções: profundo 1:2 (pé-direito 2,7), isométrico 1:1 (pé-direito 2,7m), largo 2:1 (pé-direito 2,7 m) e alto 1:1 (pé-direito 5,4 m).
9**	Geometria – dimensão (K) Largura (m) Profundidade (m) Altura (m)	4	Dimensões (2 m, 4 m, 8 m e 16 m): pequeno (4 m ² e 8 m ²), médio (16 m ² e 32 m ²) e grande (64 m ² e 128 m ²).
10	Padrão de ocupação (h)	3	8h, 12h, 24h
11**	Obstrução externa (°)	4	Ângulo de obstrução: 0° com influência do piso externo (térreo), 0° sem influência do piso externo, 40° sem influência do piso externo e 80° sem influência do piso externo.
Total de combinações amostradas		10.450.944	

Fonte: Autor.

Nota:

* variáveis independentes contínuas transformadas em discretas uniformes – tratam-se do mesmo objeto

** variáveis independentes contínuas transformadas em discretas uniformes – devido ao conceito adotado no trabalho.

Para este estudo, algumas variáveis independentes contínuas (ver variáveis destacadas com * na Tabela 15) foram agrupadas e adotadas como variáveis discretas uniformes, pois não fazia sentido serem observadas separadamente. Apesar de dificultar as observações do Hipercubo Latino, Vianna (2013) já descreveu a interação de variáveis contínuas e discretas em uma mesma amostragem, assim como Shen e Tzempelikos (2012) o fizeram agrupando características de vidros e de

²³ Índice de ambiente K: é uma relação entre largura, comprimento e altura que permite classificar ambientes com diferentes dimensões sob o ponto de vista de iluminação (considerando distribuição de luz uniforme).

ambientes em índices, transformando variáveis contínuas em discretas e, posteriormente, amostrando-as. Entre essas variáveis, estão:

- Latitude, Longitude, Altitude, GDA, GDR, RSG_a e Nb_a, todas correspondendo a uma mesma localidade. A escolha das cidades se deu de forma a abranger Latitudes alta, média e baixa dentro do Brasil; e
- para T_{VIS} e FS, o objeto considerado foi o vidro, escolhido de forma a considerar balanços entre valores “altos médios e baixos” entre as duas variáveis (ver Tabela 16).

Tabela 16– Descrição dos vidros selecionados para a parametrização conforme relações entre T_{VIS} e FS

Vidro	T _{VIS}	FS	T _{VIS} /FS	T _{VIS} - FS	*LEGENDA:
Clear 6 mm	0,88	0,819	1,07	a-a	a - alta b - baixa m - média (intermediária)
Grey 6 mm	0,43	0,602	0,71	b-a	
Reflective (Steel Coat) Tinted LoTrans 6 mm	0,05	0,232	0,22	b-b	
LoE Tinted 6 mm	0,50	0,450	1,11	m-m	
LoE Spectrally Selective Clear 6 mm	0,77	0,468	1,65	a-m	
LoE Spectrally Selective Tinted 6 mm	0,46	0,351	1,31	m-b	
Difusor	0,12	0,299	0,40		

Fonte: Adaptado de: Biblioteca do EnergyPlus (US-DOE, 2011).


Dentro dessa mesma abordagem, outras variáveis independentes contínuas também foram agrupadas conforme o conceito que se queria trabalhar e, assim, consideradas como variáveis discretas uniformes (ver variáveis destacadas com ** na Tabela 15).

As Refletâncias das Superfícies foram agrupadas sob o conceito ambientes com baixa, média ou alta refletividade (BROWN; DEKAY, 2004). Quanto às aberturas, os três valores de PAF e a possibilidade de ocorrência de abertura zenital foram amostrados uniformemente (PAF 20%; PAF 50%; PAF 80%; e PAZ). Para a definição da opção de PAZ a ser utilizada, foi realizado sorteio randômico para que essa solução assumisse as seguintes condições:


- tamanho da abertura: PAZ 2% vidro claro (T_{VIS} 0,88 e FS 0,819; ver Figura 87a e c) e PAZ 40% vidro translúcido (T_{VIS} 0,12 e FS 0,299; ver Figura 87b e d); e

- PAZ concentrado (ver Figura 87a e b) ou distribuído em quatro aberturas (ver Figura 87c e d).


Figura 87 – Exemplo da variação de distribuição e tamanho das aberturas zenitais (PAZ)




(a) PAZ 2% – abertura concentrada



(b) PAZ 40% – abertura concentrada



(c) PAZ 2% – abertura distribuída




(d) PAZ 40% – abertura distribuída


Fonte: Autor.

Proteções solares foram consideradas inexistentes, verticais (3 AHS), horizontais (3 AVS) ou combinadas (só para a opção 45° para horizontais e verticais).


Figura 88 – Exemplo das variações de proteções solares (AVS e AHS)




(a) modelo sem *brise*



(b) modelo com *brises* horizontais 45°



(c) modelo com *brises* verticais 45°




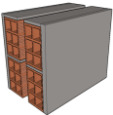

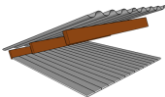
(d) modelo com *brises* combinados 45°

Fonte: Autor.

A Densidade de Carga Interna agrupou os valores das cargas referentes às pessoas (W/pessoa) segundo a quantidade e a taxa de metabolismo e referentes aos equipamentos (W/m²). A DPI foi considerada separadamente para poder ser combinada com o agrupamento das outras duas (pessoas e equipamentos). Como os ambientes não têm atividade específica, consideraram-se genericamente como carga de equipamentos computadores com capacidade de 150 W, de acordo com Melo (2012), distribuídos por metragem quadrada, sendo 25 m²/equipamento, 10 m²/equipamento e 5 m²/equipamento. Logo, adotaram-se as seguintes densidades: 6 W/m², 15 W/m² e 30 W/m², respectivamente. Para os valores de taxa metabólica das pessoas, adotou-se 120 W/pessoa, valor padrão do Viper-Grasshopper. Para a densidade de pessoas por atividade, escolheram-se valores mínimos médios e elevados da ASHRAE 90.1 – *Addendum Building Envelope Trade-Off Schedules and Loads* (ASHRAE, 2013). A atividade com menor densidade adotada foi a de 35 m²/pessoa e a de maior foi a de 0,93m²/pessoa; esses valores correspondiam a multifamiliar/hotel aproximadamente e a estações de transporte, respectivamente. Dentro desses limites, escolheu-se como valor intermediário 2 m²/pessoa, que pode ser aproximado das atividades de museu e centro de convenções.

As propriedades térmicas dos fechamentos opacos, da mesma forma que a refletância das superfícies, foram agrupadas sob o conceito ambientes adiabáticos, com pouca troca de calor com o exterior e com média troca, segundo a Tabela 17. As composições de parede e a cobertura foram selecionadas das opções disponíveis no Anexo Geral V do RAC-C (INMETRO, 2013). Como o foco do trabalho foi avaliar o desempenho da iluminação, essa simplificação quanto às propriedades térmicas foi uma alternativa para reduzir o número de variáveis a serem combinadas.

Tabela 17 – Propriedades térmicas adotadas para parametrização

TRANSMITÂNCIAS E ABSORTÂNCIAS TÉRMICAS ADOTADAS					
	TRANSMITÂNCIA				ABSORTÂNCIA
	Média Troca	CÓDIGO NO ANEXO V DO RAC	Pouca Troca	CÓDIGO NO ANEXO V DO RAC	SUPERFÍCIES EXTERNAS (paredes e coberturas)
Paredes	3,65	19	1,25	39	Adotada a média do programa S3E (CERTI, 2011) para parede e piso em todos os casos = 0,5.
					
Coberturas	3,73	1	1,75	6	REFLETÂNCIA (entorno)
					Refletância do piso externo
					20%
					Refletância da obstrução
					40%

Fonte: Anexo Geral V do RAC-C (INMETRO, 2013).

As geometrias foram definidas buscando representar variações de tamanho e de proporções devido à importância da configuração de um ambiente em proporção 1:2 ou 2:1, como ilustrado na Figura 42, p. 184. O fator 1 das proporções assumiu os valores 2 m, 4 m e 8 m, enquanto o fator 2 assumiu os valores 4 m, 8 m e 16 m. Um exemplo das dimensões do um ambiente Profundo (1:2) pequeno seria 2 m x 4 m, com 2,7 m de pé-direito. Idealizaram-se ambientes de tipologia isométrica, larga, profunda e alta. Os índices de ambiente K das combinações entre tamanho e proporções variam entre 0,6 e 2,5 e foram obtidos através da Equação 26.

$$K = \frac{C \times L}{h(C + L)} \quad (26)$$

Onde:

K: índice de ambiente;

C: comprimento;

L: largura; e

h: altura.

Para a consideração da obstrução externa, adotaram-se quatro condições: um ambiente térreo sem obstrução (influência da refletância do piso externo), um ambiente com ângulo de obstrução 80° (andar baixo), com ângulo de obstrução 40° (andar no meio de um edifício) e sem obstrução e sem a influência do piso externo (topo do edifício ou meio do edifício sem obstrução). A refletância do entorno foi mantida fixa em 0,4, de acordo com Leder (2007). Esse valor foi obtido experimentalmente como refletância média de uma amostra de prédios em Florianópolis, descontando-se as áreas envidraçadas.

Quanto aos parâmetros considerados individualmente, a DPI foi definida como 2 W/m², 12 W/m² e 20 W/m². O valor mais baixo foi escolhido baseando-se no *Guia de aplicação de iluminação para edificações sustentáveis* da Philips, elaborado com estratégias de projeto para a obtenção da certificação LEED (PHILIPS, 2012). Esse trabalho visa à avaliação de ambientes e não edificações de maneira geral, assim o valor mais baixo de DPI foi estimado para ser inferior ao de uma área de circulação iluminada por LEDs. Para 12 W/m², consideraram-se lâmpadas fluorescentes e para 20 W/m², locais que precisem de um projeto luminotécnico com mais iluminação, como áreas de lojas ou supermercados, ou projetos menos eficientes (PHILIPS, 2009).

As iluminâncias de projeto foram fixadas em 100 lux (por exemplo, áreas gerais da edificação), 300 lux (por exemplo, recepções, áreas de venda) e 500 lux (por exemplo, escritórios, atividade de leitura, área de vendas, cozinhas) (ABNT, 2013). Esses valores foram adotados considerando-se a iluminância média do ambiente.

Para as orientações, escolheram-se as orientações cardeais e as colaterais. Para as redes neurais, incluiu-se o valor 359° N, de acordo com o Capítulo 4. Como seriam propostos elementos de proteção solar,

entendeu-se que a inclusão das orientações colaterais seria importante para a descrição do fenômeno.

O padrão de uso e ocupação foi considerado 8h (das 8h às 18h, com intervalo para almoço das 12h às 14h), 12h (das 8h às 20h) e 24h, adotando-se 100% de ocupação nesses horários e ocupação nula nos demais. Assim, foi possível avaliar a diferença entre ocupações em que a luz natural é mais ou menos disponível. A ocupação foi considerada constante durante todo o ano, não sendo descontados finais de semana ou feriados.

Para todos os casos, assumiu-se o sistema de condicionamento padrão adotado pelo programa Viper/Grasshopper/DIVA. O programa utiliza cálculo de carga térmica com base na classe Ideal Loads Air System e, para obtenção do consumo, tem sua carga em uso dividida pelo coeficiente de performance (COP) (SOLEMMMA LLC, 2014). Como valor de COP, adotou-se $3,19W_{\text{térmico}}/W_{\text{elétrico}}$, correspondente a um equipamento *split* classificação A, de acordo com as tabelas PROCEL-Inmetro (INMETRO, 2013).

A taxa de infiltração também foi mantida constante. Como essa taxa representa a influência no comportamento térmico da edificação, que não é o principal foco deste trabalho, adotou-se o valor intermediário utilizado por Melo (2012) de 1 ACH.

Todos os casos foram simulados para os climas das cidades de Florianópolis, Brasília e Belém, adotando-se arquivo climático SWERA, obtido no sítio do EnergyPlus (US-DOE, 2013).

Para testar as redes neurais, foram propostos casos com parâmetros diferentes dos amostrados; entretanto, apenas um parâmetro é variado por vez a fim de observar o seu efeito no desempenho das redes. A Tabela 18 mostra na primeira linha (em azul) as características do modelo-base e os parâmetros alterados e seus respectivos valores para os casos “nunca vistos” para as características da descrição do edifício nas células brancas. Os padrões de uso e ocupação nunca vistos são 10h (8h às 18h) e 18h (8h às 24h).

Tabela 18– Valores dos parâmetros alterados para os casos do “conjunto nunca vistos”

REFLETÂNCIA		ABERTURAS		PROTEÇÃO SOLAR		VIDRO	ORIENT.	DCI		PROPRIED. TÉRMICAS (comp. das superfícies)	CARACT. AMBIENTES (proporção e dimensão)	OCC.	ENTORNO
reflet. TETO (%)	reflet. PAREDE (%)	PAF (%)	PAZ (%)	AVS (°)	AHS (°)	Vidro: T _{vis} e FS	azimute (°)	Equip. (W/m ²)	Ocup. (W/m ² .pessoa)	adiabático/ externo	Ke e geometria (m)	padrão de uso (h)	obstrução (°)
80	40	50	0	0	0	0,88/ 0,819	0	15	0,53	pouca troca	4 x 4 x 2,7	12	0º sem piso
60	60	30	10 % vidro leitoso (0,12/ 0,299)	15	15	Refletivo 6mm (0,221/ 0,365)	222,5				11,31 x 11,31 x 2,7	10	20
		40		50	55	Refletivo 6mm (0,301/ 0,4)	67,5				3 x 7 x 2,7	18	60
		50				Cinza 3mm (0,611/ 0,716)	112,5				9 x 13 x 2,7		
		60											

Fonte: Autor.

Também foram consideradas no conjunto “nunca vistos” as iluminâncias de 200 lux e 750 lux. Essas iluminâncias foram simuladas para um lote de conjunto amostrado (Florianópolis, occ24h). Para alguns casos, também foram usadas outras localidades (São Paulo e Salvador) e novamente se usou o conjunto amostrado (occ12h, 500 lux). Os parâmetros dessas cidades podem ser vistos na Tabela 10 do Capítulo 6, p. 222.

7.3.2 Parametrização dos modelos e simulação integrada de iluminação natural e energia

Como descrito no item 7.2.2, para este grupo adotaram-se duas ações:

- (1) a validação Viper Grasshopper/DIVA/Daysim-EnergyPlus; e
- (2) o conceito do algoritmo.

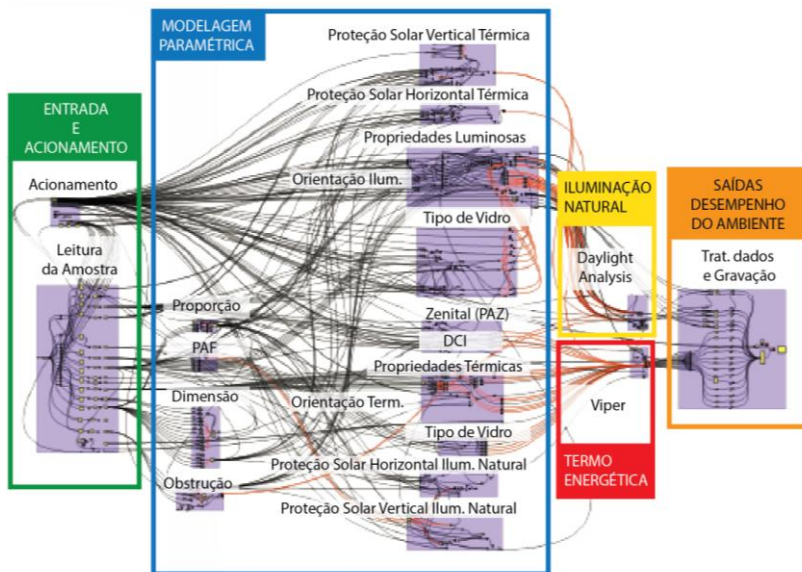
7.3.2.1 *Resultados da ação 1 – validação Viper Grasshopper/DIVA/Daysim-EnergyPlus*

A calibração entre os modelos gerados nos programas Daysim-EnergyPlus, DIVA e Grasshopper permitiu alinhar as simulações dos casos “nunca vistos” que foram realizadas diretamente no DIVA com as simulações baseadas no algoritmo programado no Grasshopper. Durante o processo em discussão com os desenvolvedores do programa, descobriu-se uma incompatibilidade entre os arquivos-base *.idf do Grasshopper (Viper) e do DIVA (Thermal). Ambas as interfaces consideram o ambiente como apenas uma zona térmica e, ao definir se as superfícies desenhadas são parede, piso ou teto, o programa automaticamente determina se as superfícies são ou não voltadas para o exterior. Descobriu-se que o DIVA-Thermal modelava o piso voltado para o exterior, ao passo que o Grasshopper-Viper o definia como em contato com o solo. Essa alteração estava implicando uma diferença significativa entre as simulações. Com essa correção, foi possível alinhar os arquivos-base *.idf dos dois programas e garantir que os resultados simulados a serem usados para treinamento e teste (conjunto “nunca vistos”) das redes neurais estivessem coerentes.

7.3.2.2 *Resultados da ação 2 – o conceito do algoritmo*

A parametrização dos modelos, apesar de bastante trabalhosa devido ao grande número de variáveis, permitiu que diferentes amostragens pudessem ser simuladas utilizando-se o mesmo algoritmo. O processo de preparação da amostra de 200 casos, por exemplo, que levaria cerca de 40 horas pela procedimento de modelagem usual, pôde ser realizado em cerca de 10 minutos. O algoritmo gerado no Rhinoceros/Grasshopper/DIVA pôde ser utilizado para as outras amostragens baseadas nesse mesmo conjunto de parâmetros. A Figura 89 ilustra o algoritmo, destacando em verde a área em que a amostragem ALH é lida e a sequência de simulações é acionada; em azul, a área com as características geométricas dos modelos; em amarelo, onde ocorre a simulação de iluminação natural; em vermelho, onde ocorre a simulação termoenergética; e, em verde novamente, onde é feita a leitura dos resultados e onde são calculadas as médias espaciais e a DPU.

Figura 89 – Algoritmo gerado no Grasshopper, legendado de acordo com as área das funções realizadas



Fonte: Felipe et al. (2015).

O algoritmo foi programado para oferecer como dado de saída Autonomia da Luz Natural Espacial para 50% e 30% das horas do ano; três faixas de Iluminâncias Úteis para esses mesmos percentuais de horas de atendimento; Autonomia da Luz Natural Contínua Espacial para os mesmos percentuais; Fator de Luz Diurna Espacial; Consumo para Aquecimento, Resfriamento, Iluminação e Equipamentos; Ganhos Térmicos Diretos; Ganhos Térmicos Difusos; Ganhos Térmicos referentes a Equipamentos, Iluminação e Pessoas; Energia Elétrica Primária; Emissões de Carbono atribuídas ao consumo de energia em geral e à energia elétrica; e Densidade de Potência em Uso.

Para efeitos deste trabalho, foram utilizados os seguintes dados de saída referentes à iluminação natural:

- FLD espacial igual ou superior a 1,62%, referente ao atendimento de uma iluminância mínima de 300 lux, para a cidade de Florianópolis, em 50% do tempo do período de ocupação dos ambientes (MORAES; PEREIRA, 2014);

- FLD espacial igual ou superior a 1,10%, referente ao atendimento de uma iluminância mínima de 300 lux, para a cidade de Florianópolis, em 30% do tempo do período de ocupação dos ambientes (MORAES; PEREIRA, 2014);
- Iluminâncias Úteis Espaciais – sUDI_{50%} (IES LM-83-12, 2012), referente à porcentagem de área em que as iluminâncias estão entre 100 e 2.000 lux, por determinado período de tempo, nesse caso 50% das horas ao longo do ano;
- Iluminâncias Úteis Espaciais – sUDI_{30%} (IES LM-83-12, 2012), a mesma medida do item anterior, mas atendidas em apenas 30% das horas ao longo do ano;
- Autonomia Espacial da Luz Natural – sDA_{50%} (IES LM-83-12, 2012), referente à porcentagem de área que excede um valor mínimo de iluminância, por determinado período de tempo, nesse caso 50% das horas ao longo do ano; e
- Autonomia Espacial da Luz Natural – sDA_{30%} (IES LM-83-12, 2012), a mesma medida do item anterior, mas atendida em apenas 30% das horas ao longo do ano.

Quanto à energia, foram utilizados o Consumo Energético Total e o consumo para Aquecimento, Resfriamento, Iluminação e Equipamentos. Para as ações dos itens 7.3.5 e 7.3.6, incluiu-se a DPU. Os resultados das simulações foram gravados em planilha Excel.


7.3.3 Amostragem por Hipercubo Latino

Como descrito no item 7.2.3, primeiramente foi feito o teste de normalidade para o conjunto de dados de Didoné (2012). Vale salientar que o teste foi feito apenas para os valores do Consumo Total da edificação, pois foi o parâmetro de desempenho utilizado pela autora. Como esse teste resultou em descarte da hipótese de normalidade, optou-se por experimentar diferentes tamanhos de amostra.

De acordo com o exposto na Figura 86 e na Tabela 15, foram elencados 11 parâmetros a serem amostrados, o que, de acordo com Bartlett, Kotrlík e Higgins (2001), resultaria em 55 interações para variáveis discretas e 110 para contínuas. Como as variáveis contínuas foram agrupadas em discretas, optou-se por partir de uma amostra mínima de 100 casos.

Com base nas proporções de parâmetros e na quantidade de casos amostrados nos trabalhos citados no item 7.2.3, p. 257, propuseram-se mais dois conjuntos de amostras com 200 e 300 casos sorteados independentemente. Para os três grupos, cada parâmetro teve a mesma quantidade de observações sorteadas uniformemente, como mostra a Figura 90. Dessa forma, garantiu-se proporcionalidade entre as amostras.

Figura 90 – Número de casos por parâmetros para as amostragens feitas pelo método Hipercubo Latino para 100, 200 e 300 casos



A simulação integrada é significativamente mais demorada do que a simulação energética (ver item 2.1.2, p.44). Três computadores foram utilizados para as simulações integradas, com diferentes desempenhos. Os 600 casos (três amostragens) foram divididos em três computadores com configurações diferentes, sendo simulados 200 casos em cada um, com tempos de simulações de 12, 16 e 8,5 horas (12,17 h, em média).

7.3.4 Testes do desempenho dos diferentes tamanhos de amostras para a modelagem dos parâmetros de desempenho através das RNAs

Como descrito no item 7.2.4, para este grupo adotaram-se quatro ações:

- (1) teste de normalidade das amostras;
- (2) teste da quantidade de neurônios na camada intermediária;
- (3) teste do algoritmo; e
- (4) teste do agrupamento de parâmetros de desempenho.


7.3.4.1 Resultados da ação 1 – teste de normalidade das amostras

O teste Kolmogorov-Smirnov foi realizado para cada um dos 11 parâmetros de saída (seis de iluminação natural e cinco de energia) para a amostragem de 300 casos. Primeiramente, avaliaram-se os parâmetros em escala aritmética ou linear e, diante da não observância de normalidade na distribuição, experimentou-se a escala logarítmica. Com 95% de confiança, todos os conjuntos tiveram a hipótese de normalidade descartada, com exceção do Consumo Energético Total, quando utilizada a escala logarítmica. No entanto, a aplicação da escala logarítmica levou a um excesso de deslocamento das probabilidades, configurando uma distribuição assimétrica à direita.

Diante desse resultado, foram gerados os gráficos de histograma de frequência de ocorrência de todos os parâmetros de saída para as três amostragens. Nos três casos, os histogramas de frequência para todos os 11 parâmetros de saída apresentaram distribuição semelhante. Os histogramas para todos os parâmetros de saída encontram-se no APÊNDICE E , p. 437. Isso significa que as interações ALH dos parâmetros de entrada amostrados foram congruentes em termos de resultados de saída (desempenho) para as três amostras. A Figura 91 ilustra dois dos 11 parâmetros a título de exemplo: $sDA_{30\%}$ e Consumo Total. Como se pode perceber, $sDA_{30\%}$ é o parâmetro que menos se aproxima de uma distribuição normal, os seis parâmetros de iluminação natural apresentaram distribuição compatível com a apresentada. Depois do Consumo Total, as curvas de consumo para Resfriamento e Aquecimento foram as que mais se aproximaram de uma distribuição normal; entretanto, com distribuição assimétrica à esquerda (os casos que não estão na Figura 91 encontram-se no APÊNDICE E , p. 437). Essa avaliação permitiu concluir que, apesar de não se tratar de distribuições normais, nem em escala real nem em logarítmica, as

amostras são compatíveis entre si em termos de frequência de ocorrência. Além disso, a maior aproximação dos parâmetros de consumo da distribuição normal deverá facilitar a sua modelagem.

Figura 91 – Perfil de distribuição por frequência de ocorrência dos resultados dos parâmetros de saída resultantes das amostras por Hipercubo Latino para 300, 200 e 100 casos



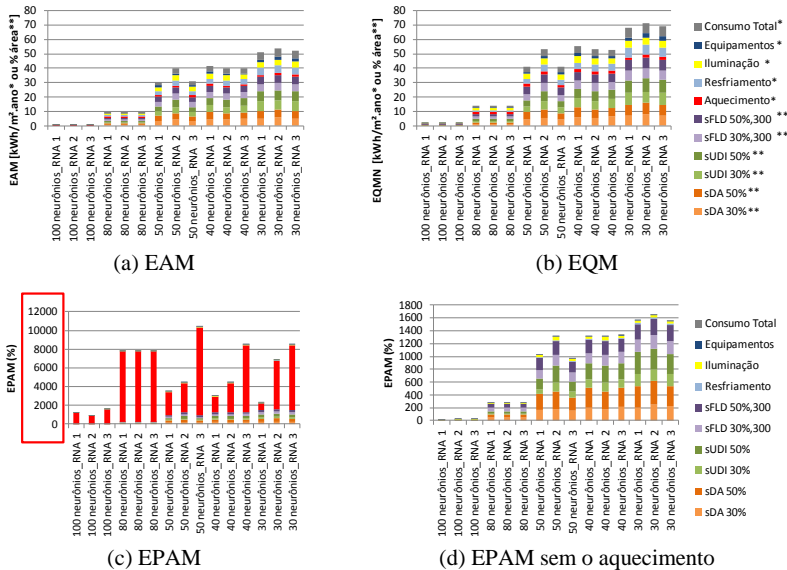
7.3.4.2 Resultados da ação 2 – teste da quantidade de neurônios na camada intermediária

Para esta etapa, os 11 parâmetros amostrados pelo Hipercubo Latino foram desmembrados em 20 variáveis, utilizadas como nós de entrada da rede neural. Foram elas: refletância teto, refletância parede, PAF, PAZ, distribuição da abertura zenital única e distribuída, AHS, AVS, T_{VIS} , FS, orientação, DCI equipamentos, DCI pessoas, propriedades térmicas, largura, profundidade, altura, padrão de ocupação, ângulo de obstrução e influência do piso externo. Os

neurônios de saída foram os 11 parâmetros de saída do algoritmo do Grasshopper, listados no item 7.3.2.

Nesta etapa as redes foram treinadas apenas com a amostra de 300 casos. Aplicando-se a heurística da Equação 8, p. 83, treinaram-se redes com 30 neurônios, passando a 40, 50, 80 e 100. A Figura 92 exibe os resultados dos erros EAM (a), EQM (b) e EPAM (c) e (d) para cada parâmetro de saída. Para EAM e EQM, a escala do eixo das ordenadas é apresentada em kWh/m²/ano para os parâmetros de saída de energia e em percentual de área atendida para os parâmetros de iluminação natural. O EPAM apresentado na Figura 92c e d é dado em percentual para ambos os parâmetros de saída. O gráfico ilustrado na Figura 92c apresenta os mesmos dados que o gráfico da Figura 92d; entretanto, neste último, foram retirados os erros atribuídos ao consumo por Aquecimento para melhor observação dos resultados dos outros parâmetros de saída. Pode-se observar uma melhora no desempenho da rede conforme se aumentou o número de neurônios. Entretanto, vale ressaltar que, ao considerar o conjunto “nunca vistos”, essa tendência pode se alterar, como observado nos capítulos anteriores.


Figura 92 – Comparação entre as quantidade de neurônios na camada interna para a amostra de 300 casos para todo o conjunto de dados das redes



7.3.4.3 Resultados da ação 3 – teste do algoritmo

Quanto ao algoritmo de aprendizado, foram testados os algoritmos Regularização Bayesiana, Gradiente Descendente e Levenberg-Marquardt. O primeiro foi o mesmo utilizado na etapa anterior para a análise do número de neurônios na camada interna. Nesta etapa as redes também foram treinadas apenas com a amostra de 300 casos. A Figura 93 mostra os resultados dos erros EAM e EPAM para cada parâmetro de saída e para cada um dos três algoritmos. O algoritmo Regularização Bayesiana foi o que apresentou o melhor desempenho, com a soma de todos os EPAMs igual a 17%, seguido do Gradiente Descendente, que somou 270%, e do Levenberg-Marquardt, que chegou a 3,444%, descontando-se o EPAM para Aquecimento (ver Figura 93b). Apesar de o Gradiente Descendente apresentar melhor desempenho para modelar o aquecimento, como os valores absolutos desse parâmetro são muito baixos, optou-se por seguir com a aplicação do algoritmo Regularização Bayesiana.

Figura 93 – Comparação entre os algoritmos para a amostra de 300 casos para todo o conjunto de dados das redes, considerando a média das três RNAs




7.3.4.4 Resultados da ação 4 – teste do agrupamento de parâmetros de desempenho


Finalmente, passou-se para os testes de configuração da rede quanto ao agrupamento dos parâmetros de saída: Todos Juntos (Iluminação Natural e Energia), só Iluminação Natural e somente Energia. Nesta etapa foram avaliadas as três amostras, adotando-se a quantidade de neurônios na camada interna, conforme a quantidade de padrões de entrada e saída, baseando-se na ação do item 7.3.5.2 e no algoritmo de aprendizagem Regularização Bayesiana, conforme ação apresentada no item anterior.

A separação dos nós de saída por natureza, em geral, aumentou os erros de predição para os parâmetros de Iluminação Natural, com exceção das redes baseadas na amostragem de 100 casos, que praticamente não apresentaram alteração nos valores dos erros (menos de 1%) (ver Figura 94a e Figura 96a). Uma possível justificativa é de que as três amostras possuem combinações diferentes dos parâmetros de entrada e, apesar da mesma quantidade de observações de cada um deles e da mesma distribuição dos valores de saída, essas diferentes combinações podem ser mais representativas dos efeitos da iluminação natural. Com isso, os parâmetros de saída dependeram menos da relação com os nós de saída de energia, fazendo com que nos ajustes de pesos da rede a influência dos nós de saída de Energia não fosse muito relevante. Já para os dados de saída de Energia, a separação impactou em melhora substancial no desempenho da rede, diminuindo o EPAM pela metade, ver (Figura 94a e Figura 95a).


Figura 94 – Comparação entre as três amostras, considerando todos os parâmetros de saída na mesma RNA, para todo o conjunto de dados da rede



(a) EPAM



(b) EAM




(c) EQM


Os valores de EPAM dos gráficos da Figura 94a e da Figura 95a foram mascarados pelos elevados valores de erro para Aquecimento, como já ocorreu nos outros testes desta pesquisa. Quanto aos parâmetros de saída de Energia, desconsiderando-se os valores de EPAM para Aquecimento, os maiores erros percentuais ocorreram para o consumo referente à Iluminação. Entretanto, os valores de EPAM para Iluminação, para as redes com todos os nós de saída, não ultrapassaram 4%, enquanto os demais valores para nós de saída de energia não ultrapassaram 1% cada um. Quando os erros dos nós de saída de Energia foram observados separadamente, o EPAM não ultrapassou 0,25% para a amostra de 100 casos e 0,05% para a amostra de 300 casos, sendo, para esta última, grande parte dos erros atribuída ao consumo por Iluminação; mesmo assim, esse erro é considerado baixo, na ordem de 0,04 kWh/m²/ano.

Quanto ao desempenho das redes relacionadas ao tamanho das amostras, as redes com nós de saída exclusivos de Energia apresentaram o padrão esperado, com erros decrescentes conforme se aumentava o número de casos nas amostras, com exceção do Aquecimento (ver Figura 95a, b e c).


Figura 95 – Comparação entre as três amostras, considerando os parâmetros de saída de Consumo Energético, para todo o conjunto de dados da rede



(a) EPAM



(b) EAM




(c) EQM

Já a diferença de erros, EPAM, entre as redes com todos os padrões de saída juntos (ver Figura 94a) e as redes só com Iluminação Natural (ver Figura 96a) mais que dobrou. Observando os nós de saída de iluminação natural, pode-se constatar que os maiores erros foram para o sFLD, seguido de sUDI, sendo as de 30% previstas com mais precisão entre as variações de atendimento 30% e 50%.


Pode-se observar também que, para as redes só com parâmetros de Iluminação Natural, a amostra de 300 casos se mostrou mais irregular, quando considerados os resultados das três redes neurais rodadas (ver Figura 94a, b e c), enquanto a RNA 3 para 200 casos apresentou erros significativamente fora do padrão. Esse resultado justifica-se pelo fato de que cada RNA inicia seu processo de ajuste de pesos de um ponto aleatório da superfície do erro. Essa rede traçou um caminho notadamente diferente das outras duas, nesse caso a rede poderia ser desconsiderada. Essa observação frisa a importância da

simulação de várias redes com a mesma configuração, evitando-se trabalhar com resultados que não expressem o potencial da rede.


Figura 96 – Comparação entre as três amostras, considerando os parâmetros de saída de Iluminação Natural, para todo o conjunto de dados da rede



(a) EPAM



(b) EAM



(c) EQM

Como principais conclusões, as redes tiveram melhor desempenho com cerca de 100 neurônios na camada intermediária e com o algoritmo de aprendizagem Regularização Bayesiana. O acréscimo do número de neurônios aumenta também o tempo de processamento, que variou entre 30 minutos para 30 neurônios até 4 horas para 100 neurônios.

Os agrupamentos dos parâmetros de saída mostraram comportamentos distintos, visto que os erros na predição dos parâmetros de saída de Iluminação Natural aumentaram quando utilizados separadamente, ao passo que os erros dos parâmetros de Energia reduziram pela metade com a separação dos parâmetros.

Como conclusão final, as três amostras apresentaram resultados de erros baixos, em geral nenhum parâmetro apresentou EPAM maior

que 10% quando excluído o EPAM do Aquecimento. Logo, em todos os outros casos, indica-se fazer um balanço entre o tempo de processamento das redes e os erros aceitos, pois os valores de erros obtidos permitiram o uso de qualquer uma das três amostras. Decidiu-se adotar a amostra de 200 casos por ser mais conservadora que a de 100 casos, mas por demandar menos tempo de processamento que a de 300 casos. O agrupamento de variáveis de diferentes naturezas apresentou influência significativa, possivelmente pela relação de ajuste de pesos da rede conforme os nós de saída. A piora no desempenho dos padrões de saída de Iluminação Natural com a separação dos nós e a melhora por parte dos padrões de energia merecem mais investigações. Entretanto, aponta-se por uma dependência de algum parâmetro de energia para o melhor desempenho dos parâmetros de iluminação natural, muito provavelmente o de consumo em Iluminação.

7.3.5 Investigação dos agrupamentos dos parâmetros de desempenho diante de variações paramétricas de características da descrição do edifício

Nesta etapa, acrescentaram-se como parâmetros de entrada da rede a Densidade de Potência em Uso e a Iluminância-alvo, aumentando o número de nós na camada de entrada da rede para 22. Conforme o desempenho na etapa anterior, o algoritmo adotado foi a Regularização Bayesiana. Com o aumento de neurônios na camada de entrada, fez-se necessário novo teste para a verificação da adequabilidade do número de neurônios na camada oculta. Assim, os resultados são apresentados de acordo com três ações:


- (1) teste do agrupamento de parâmetros de desempenho;
- (2) ajuste do número de neurônios; e
- (3) comparação entre os resultados, adotando as duas abordagens de teste da rede: literatura e “nunca vistos”.

7.3.5.1 Resultados da ação 1 – teste do agrupamento de parâmetros de desempenho

Na primeira ação, quatro opções de agrupamentos de parâmetros de desempenho foram testadas: Energia e Iluminação Natural, Energia e DPU, Iluminação Natural e DPU e DPU isoladamente. Seguindo com a estimativa da quantidade de neurônios ocultos multiplicando-se a quantidade de entradas pela de saída, o número de neurônios na camada interna para cada solução resultou em 242, 132, 154 e 22, respectivamente.

A Figura 97 apresenta o erro quadrático médio normalizado (EQMN) para os quatro agrupamentos para a rede de forma geral. Pode-se perceber que o agrupamento Iluminação Natural + DPU foi o que apresentou pior desempenho, especialmente para DPU. A fim de facilitar a observação, a Figura 98 apresenta os mesmos resultados, mas sem esse agrupamento, acrescentando-se os gráficos referentes ao conjunto de treinamento e de teste.

Figura 97 – Comparação entre os quatro agrupamentos de variáveis de desempenho para todo o conjunto de dados das redes (descrição do edifício)






A escala de erros do conjunto de treinamento da Figura 98a foi destacada de modo a permitir uma melhor visualização do padrão dos erros, pois não seguiu a escala dos outros dois gráficos da mesma figura: (b) e (c). Observando-se os gráficos, pode-se constatar que os parâmetros de energia, quando separados, apresentaram melhor desempenho para o conjunto de treinamento, já para o conjunto “nunca vistos” essa diferença não foi significativa ou chegou a ser invertida. Essa inversão de tendência de erro pode ser notada em especial para Consumo em Iluminação, inferindo-se que essa variável deve ter a sua generalização beneficiada pelo ajuste de pesos da rede quando os parâmetros de Iluminação Natural são considerados. Os parâmetros de Iluminação Natural, por sua vez, apresentaram erros no mínimo duas vezes maiores quando apresentados independentemente à rede (ver Figura 97).

A variável DPU apresentou erros elevados de forma discrepante quando apresentada à rede com os parâmetros de Iluminação Natural. De acordo com a Figura 97, o EQMN chegou a quase 9. Quando

apresentada com os parâmetros de energia, o EQMN não passou de 1, mas ainda foi cerca de cinco vezes maior do que quando apresentado individualmente à rede (ver Figura 98c). Já que a DPU é uma variável derivada do Consumo de Iluminação artificial, deve se beneficiar do ajuste de pesos da rede a essa variável. Já a combinação com parâmetros de iluminação natural piorou muito o desempenho desse parâmetro para os três conjuntos (treinamento, teste e rede completa). O único caso em que a DPU apresentou melhor desempenho quando agrupada foi quando se reuniu aos parâmetros de Energia para o conjunto de treinamento (ver Figura 98a). Entretanto, a escala de erros desse conjunto é muito menor que a dos outros, fazendo com que essa diferença seja menos perceptível.

Figura 98 – Comparação entre os três agrupamentos de variáveis de desempenho, excluindo-se DL+DPU para cada conjunto de dados da rede (descrição do edifício)



Legenda:

Em outra escala Energia+Iluminação Natural_242 neurônios Energia+DPU DPU_NV_22neurônios


7.3.5.2 Resultados da ação 2 – ajuste do número de neurônios

Quanto aos testes da quantidade de neurônios na camada intermediária para o agrupamento Energia+Iluminação Natural, cada uma das três configurações adotadas, com 242, 100 e 33 neurônios ocultos, comportou-se diferentemente nos conjuntos de treinamento e teste (ver Figura 99). Pode-se perceber que quanto maior o número de

neurônios, maior a convergência (conjunto de treinamento). Entretanto, a generalização (conjunto teste “nunca vistos”) não segue o mesmo padrão; nesse conjunto, a maioria dos parâmetros de saída apresentou erros menores para a configuração de 100 neurônios. As exceções foram $sDA_{30\%}$, $sDA_{50\%}$ e Consumo de Iluminação; esses três parâmetros de saída apresentaram melhores resultados com menos neurônios e são os mais interligados conceitualmente, além dos mais sensíveis às alterações paramétricas propostas nos modelos. Isso porque o conceito de UDI apresenta uma “linha de corte” nas áreas em que a iluminância é maior que 2.000 lux. Logo, as áreas muito iluminadas não são computadas para $sUDI$, ao passo que o sDF não computa as variações dinâmicas da luz. Logo, os três parâmetros de desempenho que apresentaram menores erros para o conjunto testes com 33 neurônios foram parâmetros mais difíceis de serem previstos e precisaram de menor precisão e maior generalização. Os outros parâmetros de saída que foram mais bem representados pela configuração de 100 neurônios são parâmetros para os quais a convergência e a generalização foram mais equilibradas. No balanço final, considerando a rede de maneira geral, a configuração com 100 neurônios apresentou melhor desempenho.

Quanto à natureza dos parâmetros de desempenho, desconsiderando-se o caso com 242 neurônios na camada interna, os parâmetros de energia apresentaram menores erros que os de iluminação. Atribui-se a isso a melhora no desempenho das redes ao ajuste de neurônios na camada interna.

Figura 99 – Comparação entre as três soluções da combinação de parâmetros Energia + DL para cada conjunto de dados da rede (descrição do edifício)




Legenda:

- Energia+Iluminação Natural_242neurônios
- Energia+Iluminação Natural_100neurônios
- Energia+Iluminação Natural_33neurônios

Considerando as redes que só apresentam DPU como parâmetro de saída, o ajuste do número de neurônios na camada interna foi feito através da aplicação da heurística da Equação 8, p. 83. A equação retornou 22 neurônios; entretanto, sua aplicação piorou o desempenho das redes no geral (ver Figura 100c). Novamente, houve melhora no conjunto de treinamento (ver Figura 100a), mas significativa piora no

conjunto “nunca vistos”, com erro absoluto médio de mais de 30% $DPI_{requerida}$ (ver Figura 100b). Para o conjunto total de dados, o desempenho melhora devido ao tamanho do conjunto de treinamento, que é bem maior que o de teste, fazendo com que o erro geral da rede diminua.

Figura 100 – Comparação entre as duas soluções para as redes DPU para cada conjunto de dados da rede (descrição do edifício)



Legenda:

Em outra escala DPU_NV_33neurônios DPU_NV_22neurônios

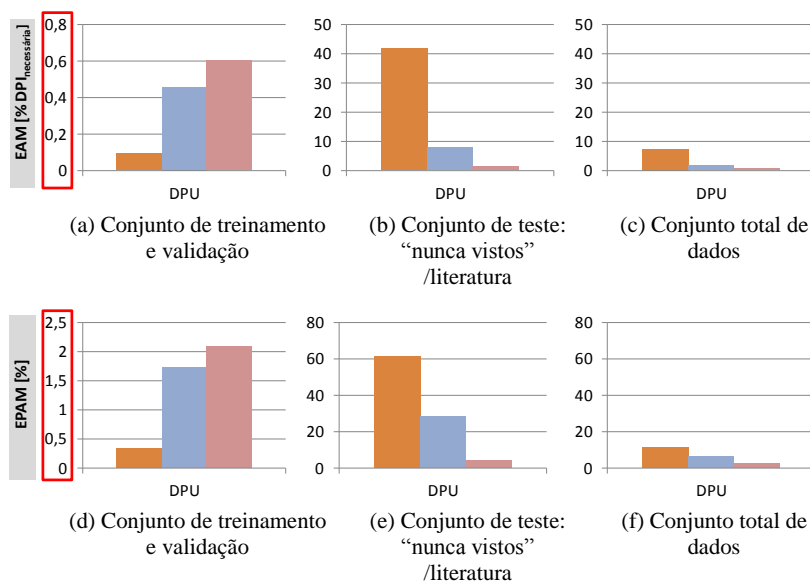
7.3.5.3 Resultados da ação 3 – comparação entre os resultados adotando as duas abordagens de teste da rede: “nunca vistos” e literatura

Na ação (3), são comparados os desempenhos das redes diante das abordagens de teste do conjunto “nunca vistos” e do conjunto de teste abordagem da literatura com separação proporcional 80% para treino e 20% para teste, de acordo com a bibliografia. A Figura 101 mostra os resultados da comparação entre as duas soluções da ação (2) e a nova solução (legenda: DPU_80_20), em que o conjunto de teste foi definido conforme o percentual do conjunto total de dados. Para esse teste, os casos do conjunto “nunca vistos” foram incorporados ao conjunto total e selecionou-se aleatoriamente 20% desse conjunto total para teste. Essa solução manteve os 22 neurônios na camada interna, referente à solução de melhor desempenho geral da rede na ação (2). Na primeira linha da Figura 101 são mostrados os erros absolutos médios; e na segunda, os percentuais médios.

Para o conjunto de treinamento, a nova solução foi a de pior desempenho, visto que os casos do conjunto “nunca vistos” foram incluídos nessa fase (ver Figura 101a e d) Entretanto, quanto à

magnitude, a escala de erros do conjunto de treinamento continua muito inferior à do conjunto de teste. De acordo com a Figura 101e, os erros diminuíram consideravelmente para o conjunto de testes, com o EPAM variando de 60% e 28% para as soluções avaliadas segundo o conjunto “nunca vistos” e para menos de 10% para o conjunto testado com a abordagem da literatura. Diante desses percentuais altos, o desempenho do conjunto total de dados também melhorou.

Figura 101 – Comparação entre as diferentes abordagens de teste das redes para cada conjunto de dados da rede (descrição do edifício)



Legenda:

- Em outra escala
 ■ DPU_NV_33neurônios*
 ■ DPU_NV_22neurônios*
 ■ DPU_80_20**
- *testado com conjunto “nunca vistos”
- ** testado com abordagem literatura


Esses resultados sugerem que as redes podem prever, com relativa precisão, casos que fizeram parte do conjunto de interações do Hipercubo Latino, visto que se obteve EPAM igual a 3,9% para o conjunto testado com a abordagem da literatura (ver Figura 101f). Entretanto, as redes não conseguiram manter esse desempenho para casos dentro dos intervalos das variáveis adotadas para o ALH que não

essas, uma vez que, para o conjunto de teste “nunca vistos”, o EPAM mais baixo (DPU_NV_22neurônios) foi de 28,7% (ver Figura 101f).

A fim de investigar os erros para cada variável alterada no conjunto “nunca vistos”, a Figura 102 mostra os erros EAM e EPAM para cada caso, destacando-se na legenda a alteração paramétrica sofrida nas variáveis da descrição do edifício. Com base nessa figura, pode-se constatar que todos os erros absolutos médios foram superiores a 15%_{DPI^{necessária}} e inferiores a 50%_{DPI^{necessária}}. Em termos de EPAM, o menor erro foi de 27% para a Geometria 11,31x11,31 e o maior de 1.200% para o Padrão de Ocupação de 10 horas. Entretanto, esse valor foi discrepante, tendo o EPAM do grupo ficado em torno de 300%. Apenas os erros das três opções de geometria, Obstrução 60° e Padrão de Ocupação de 18 horas é que ficaram abaixo de 100%. É importante destacar que esse é um conjunto restrito, mas que todos os erros foram elevados. Os erros referentes à Orientação, ao PAF e à T_{VIS} ficaram dentro dessa média; entretanto, os testes do Capítulo 5 mostraram que redes considerando apenas esses parâmetros podem apresentar bons resultados para conjuntos “nunca vistos”. No referido capítulo, a DPU ainda não tinha sido adotada como parâmetro de saída, mas, como é uma variável diretamente correlacionada com o Consumo de Iluminação, entende-se que poderia ser suficientemente bem modelada por uma rede adequada.

O aumento da quantidade de parâmetros de entrada torna a descrição de suas relações com o fenômeno da luz natural muito mais complexa; contudo, o conjunto de treinamento não apresentou problemas em convergir os padrões, apresentando erros inferiores a 2,5%. O mau desempenho da rede remete ao poder de generalização, já que os erros do conjunto nunca vistos é que foram extremamente elevados. A melhora da generalização pode ser feita através de técnicas de manipulação dos parâmetros da rede ou possivelmente através do aumento dos exemplos da amostragem.

Figura 102 – Resultado da precisão da rede para estimar a DPU para cada caso do conjunto “nunca vistos” – parâmetros da descrição do edifício




Legenda:

 Parâmetros testados no Capítulo 5

A Figura 103 mostra os erros EAM e EPAM para os casos em que se variou a Iluminância de projeto para o conjunto “nunca vistos”. Para esses casos, os erros foram bem mais aceitáveis: em termos absolutos não ultrapassaram 11% $DPI_{necessária}$ para 750 lux e 6% $DPI_{necessária}$ para 200 lux; e em termos percentuais não ultrapassaram 12%. A condição de 750 lux foi utilizada para forçar a rede a extrapolar, visto que o valor estava fora dos limites apresentados no treinamento. Entretanto, apesar de resultar em um erro quase duas vezes maior em relação aos modelos de 200 lux, ainda é extremamente inferior aos dos casos nunca vistos referentes à descrição do edifício (ver Figura 102).

Figura 103 – Resultado da precisão da rede para estimar a DPU para cada grupo de casos do conjunto “nunca vistos” – iluminância-alvo



7.3.6 Investigação sobre o efeito da inclusão de variáveis do contexto do edifício para os diferentes parâmetros de desempenho

Nesta etapa, as variáveis do contexto do edifício foram incluídas nas RNAs através da adição dos mesmos modelos simulados para Belém e Brasília. Assim, as redes neurais passaram a ter 29 neurônios na camada de entrada. Foram acrescentados Latitude, Longitude, Altitude, GDA, GDR, RSG_a e Nb_a, de acordo com a Tabela 10.


Essas redes tornaram-se ainda mais complexas, exigindo maior esforço computacional e consequentemente aumentando significativamente o tempo de treinamento. Logo, foram propostas apenas duas configurações de agrupamentos de parâmetros de desempenho: (i) redes apenas com o parâmetro DPU e (ii) redes com dois parâmetros de iluminação natural, quatro de energia e DPU. Os parâmetros selecionados foram $sUDI_{30\%}$, $sUDI_{50\%}$, Consumo para Resfriamento, Consumo para Iluminação, Consumo Total e DPU.

Para as redes com apenas DPU como parâmetro de saída, testaram-se duas configurações de neurônios na camada interna, uma com 29 neurônios (produto do número de parâmetros de entrada pelos de saída e mesma indicação da ferramenta do EasyNN-plus) e 45 neurônios (aproximadamente a heurística da Equação 8, p. 83).

A Figura 104 mostra o erro quadrático médio normalizado para todos os testes realizados desde o item 7.3.5, p. 286, até aqui: para os quatro agrupamentos de variáveis de desempenho (Energia+Iluminação Natural, Energia+DPU, Iluminação Natural+DPU, DPU), variações dos números de neurônios e inclusão de parâmetros da descrição do edifício para a rede em geral (três cidades). Dessa forma, foi possível comparar

todas as intervenções realizadas apenas para Florianópolis e considerar as três cidades. Como se pode notar, o agrupamento Iluminação Natural+DPU continuou sendo o que apresentou o pior desempenho. Vale salientar que, devido ao esforço computacional, foram executadas apenas três redes para formar a média de erros analisada para essa solução. Contudo, as três redes apresentaram erros proporcionais entre si quando observadas individualmente. Não se descarta a possibilidade de todas estarem iniciando o treinamento em uma parte desvantajosa da superfície do erro, mas, devido à coerência entre os resultados, acredita-se que a complexidade do fenômeno da iluminação natural requer maior aprofundamento na definição da arquitetura da rede e/ou de novos exemplos para que a rede possa “aprender” melhor as funções a serem modeladas.


Figura 104 – Comparação entre todas as redes abordadas neste capítulo para todo o conjunto de dados das redes (descrição e contexto do edifício)




Na Figura 105, excluiu-se o agrupamento Iluminação Natural+DPU de modo a observar melhor o padrão de erros dos demais agrupamentos. Nessa figura, os erros foram separados para o conjunto de treinamento, conjunto “nunca vistos” e para o conjunto total de dados. Diferenciou-se a escala do gráfico do conjunto de treinamento para possibilitar a visualização dos erros. As três configurações de redes que consideram as três cidades foram destacadas na legenda com um quadro tracejado azul. No eixo horizontal do gráfico, foram apontados os parâmetros considerados pela rede: Iluminação

Natural+Energia+DPU. Para essa configuração de rede, a convergência (conjunto de treinamento) apresentou erros compatíveis com os de soluções que consideravam apenas uma localidade, ao passo que a generalização (conjunto “nunca vistos”) piorou significativamente. No conjunto “nunca vistos”, os erros dos parâmetros de Energia foram comparáveis aos erros de maior magnitude das etapas anteriores (Energia+Iluminação Natural com 242 neurônios e Energia+DPU) e os erros para $sUDI_{30\%}$, $sUDI_{50\%}$ e DPU foram ainda maiores, aumentando em mais de cinco vezes em relação às soluções com apenas uma cidade.

Figura 105 – Comparação entre todas as redes abordadas neste capítulo, excluindo-se DL+DPU para cada conjunto de dados da rede (descrição e contexto do edifício)

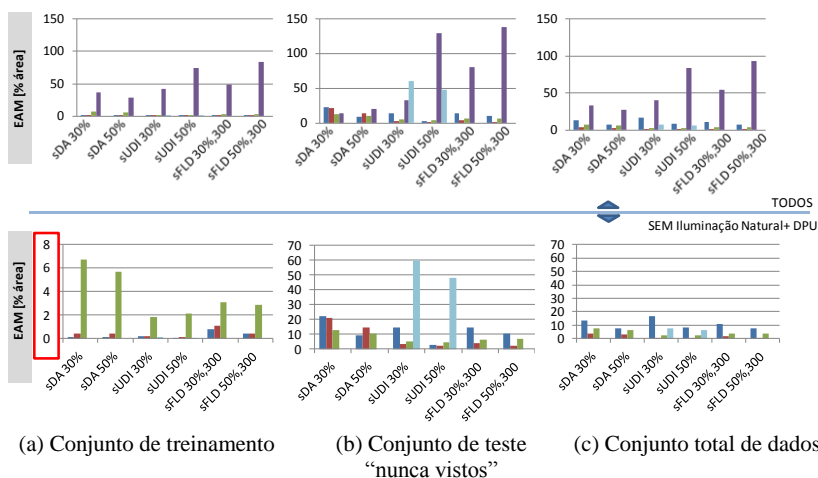


Legenda:




Para uma melhor leitura dos padrões de erros, a Figura 106, a Figura 107 e a Figura 108 exibem valores de erros absolutos e percentuais, conforme a adequabilidade, separados por natureza do parâmetro de saída. A Figura 106 mostra os parâmetros de iluminação natural para todos os agrupamentos dos quais eles fizeram parte. Na primeira linha, são exibidos os gráficos com todos os agrupamentos; e na segunda, os mesmos gráficos excluindo-se o agrupamento Iluminação Natural+DPU para facilitar a análise. Pode-se confirmar que o desempenho do conjunto de treinamento para o agrupamento das três cidades foi equivalente às soluções de melhor desempenho das etapas anteriores. Já para o conjunto “nunca vistos”, o erro absoluto médio chegou a “60% da área” ($sUDI$), em contraste, quando considerada apenas a cidade de Florianópolis, o erro absoluto médio para $sUDI_{30\%}$ e $sUDI_{50\%}$ chegou a ser inferior a “5% da área” nas configurações de rede com todos os parâmetros de Iluminação Natural e Energia.

Figura 106 – Comparação entre as redes com parâmetros de iluminação natural para cada conjunto de dados da rede (descrição e contexto do edifício)




Legenda:



A Figura 107 mostra o mesmo tipo de análise, mas para os parâmetros de energia. A mesma tendência de erros, observada para os parâmetros de Iluminação Natural, foi notada para os de Energia, em que o EAM do conjunto de treinamento da RNA para as três cidades foi compatível com o das soluções de apenas uma cidade. Já no conjunto “nunca vistos”, os erros de Iluminação e Consumo Total foram compatíveis com as soluções de pior desempenho dos agrupamentos para uma cidade (Energia+Iluminação Natural com 242 neurônios e Energia+DPU). O Resfriamento, comparativamente aos outros agrupamentos, apresentou erros equivalentes ao dobro das soluções de piores desempenhos. O resultado das cinco soluções de RNAs apresentadas nessa figura leva a considerar que um ajuste na camada interna, como foi feito no caso das redes com parâmetros de saída de

Iluminação Natural e Energia para uma cidade, pode melhorar significativamente o desempenho das redes.

Figura 107 – Comparação entre as redes com parâmetros de energia para cada conjunto de dados da rede (descrição e contexto do edifício)



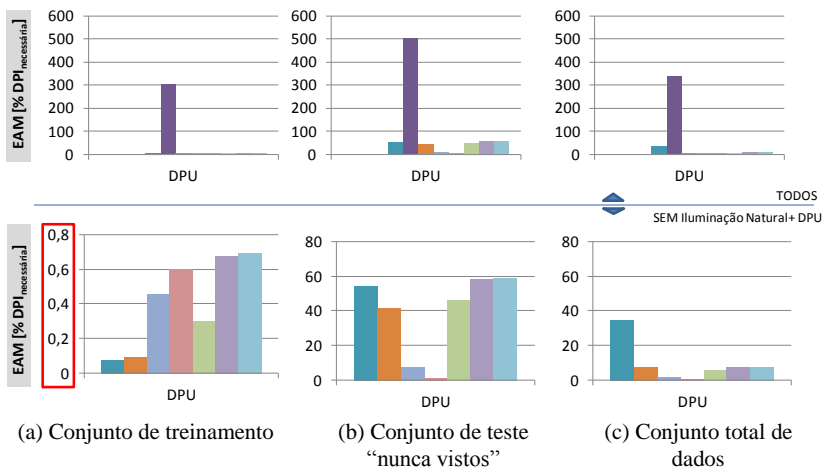
Legenda:

Na Figura 108, são apresentados os erros absolutos médios para o parâmetro de saída DPU. Na primeira linha são exibidos os gráficos com todos os agrupamentos; e na segunda, os mesmos gráficos excluindo-se o agrupamento Iluminação Natural+DPU para facilitar a análise.


Avaliando-se as duas configurações de redes que apresentam apenas DPU como parâmetro de saída para as três cidades, a configuração com 45 neurônios na camada intermediária apresentou melhor desempenho que a de 29. Esse resultado contrasta com o das redes com o mesmo agrupamento (só DPU) e apenas uma cidade, em que a rede com 33 neurônios ocultos (heurística da Equação 8, p. 83) apresentou pior desempenho que a rede de 22 neurônios ocultos (quantidade de parâmetros de entrada multiplicada pelos de saída). Essa observação é especialmente relevante para o conjunto “nunca vistos”, em que a magnitude dos erros é maior. Ao comparar os resultados da solução Iluminação Natural+Energia+DPU para as três cidades com a solução DPU com 29 neurônios ocultos também para as três cidades,

observa-se que a diferença não foi maior que 2%_{DPI_{necessária}}. Essa tendência pode ser observada tanto no conjunto de treinamento quanto no conjunto “nunca vistos”.

Figura 108 – Comparação entre as redes com os parâmetros DPU para cada conjunto de dados da rede descrição e contexto do edifício)



Legenda:




Para melhor observar os erros segundo cada grupo do conjunto “nunca vistos”, plotaram-se os erros absolutos médios para as redes DPU com 45 neurônios ocultos. A Figura 109 ilustra os erros para cada caso “nunca visto”, destacando-se na legenda a alteração paramétrica sofrida nas variáveis da descrição do edifício para as três cidades. Para a identificação das cidades, para cada variável fez-se um *dégradé* de cores em que as barras mais transparentes correspondem aos erros para Belém, as intermediárias para Brasília e as mais escuras para Florianópolis.


Os casos nunca vistos das três cidades apresentaram o mesmo padrão de erro quando analisada variável por variável. Para todos os casos, os maiores erros ocorreram para Belém, com exceção de PAF

70%. Isso mostra que o aprendizado das redes para as variáveis de entrada dos parâmetros do edifício se deu de forma semelhante para as três cidades, visto que as tendências entre parâmetros foram semelhantes. Na maioria dos casos, Brasília foi a cidade que apresentou os menores erros. Uma possibilidade é a maior ocorrência de céu limpo, diminuindo as variações de condições de céu. Florianópolis apresentou erros próximos aos de Brasília. As variações no parâmetro orientação não apresentaram praticamente nenhuma variação para a mesma cidade. Os PAFs maiores (60% e 70%) apresentaram menores erros que os menores (30% e 40%); o mesmo ocorreu com a transmissão visível. Essa tendência confirma os resultados observados no Capítulo 5, subitem 5.3.6. Em termos de EPAM médio, o grupo ficou em torno de 400%.

Figura 109 – Resultado da precisão da rede para estimar a DPU para cada caso do conjunto “nunca vistos” – parâmetros da descrição do edifício para as três cidades (descrição e contexto do edifício)




Legenda:




A Figura 110 ilustra os erros absolutos médios para as diferentes Iluminâncias e localidades do conjunto “nunca vistos”. As Iluminâncias nunca vistas apresentaram o mesmo padrão de erro para a solução para uma só cidade (Figura 103). Os erros maiores foram para 750 lux, porém o EAM nem o EPAM ultrapassaram 10% $DPI_{requerida}$ e 10% de erro, respectivamente.

Figura 110 – Resultado da precisão da rede para estimar a DPU para cada grupo de casos do conjunto “nunca vistos” – iluminância-alvo (descrição e contexto do edifício)



Os testes com as localidades nunca vistas apresentaram erros absolutos médios em torno de 75% $DPU_{requerida}$ para Salvador e 95% $DPU_{requerida}$ para São Paulo (ver Figura 111). Em termos de EPAM, os erros foram para 156% e 209%, mas, apesar de altos, ainda são menores que os erros das variáveis da descrição do edifício. Vale salientar que os casos “nunca vistos” para essas duas cidades correspondem aos 200 casos amostrados pelo AHL simulados para ocupação 12h e 500 lux; logo, seus parâmetros de descrição do edifício já haviam sido vistos pela rede, os padrões nunca vistos referiam-se somente ao local e ao clima. Comparando-se o EPAM das três categorias de variáveis do conjunto “nunca vistos”, pode-se inferir que as mais críticas foram as de descrição do edifício, seguidas das do contexto do edifício e, por fim, das de iluminâncias de projeto.

Figura 111 – Resultado da precisão da rede para estimar a DPU para cada grupo de casos do conjunto “nunca vistos” – localidades (descrição e contexto do edifício)



7.4 CONSIDERAÇÕES FINAIS SOBRE O CAPÍTULO

Neste capítulo foram apresentados os detalhes do método e os resultados para a investigação sistemática sobre as particularidades das principais variáveis do desempenho do edifício com relação às redes neurais artificiais. Para a organização das etapas da investigação sistemática, os resultados foram apresentados em grupos de ações realizadas. Primeiramente, definiram-se as variáveis-chave que compuseram a investigação. Então, foram definidos os grupos metodológicos de operacionalização e testes, que visaram responder às perguntas de pesquisa listadas no início deste capítulo. No contexto do grupo de operacionalização, foi desenvolvido um algoritmo de parametrização que viabilizou a leitura das amostras das combinações paramétricas das variáveis escolhidas, a confecção dos modelos e a simulação integrada dos casos. Três conjuntos de dados de tamanhos diferentes amostrados por Hipercubo Latino foram simulados e avaliados. A primeira ação do grupo de testes se deu através da verificação das quantidades de neurônios na camada intermediária, seguida da verificação do algoritmo de aprendizagem, e dos agrupamentos de parâmetros de saída. No grupo de testes, selecionaram-se um dos conjuntos que foram simulados para três densidades de potência em uso, três iluminâncias de projeto e três cidades. Novas redes neurais foram testadas conforme configurações de agrupamentos de parâmetros de saída, número de neurônios e tipos de conjunto de teste. Os resultados desses conjuntos de ações permitiram responder às perguntas que são aqui sintetizadas e reunidas e que respondem à pergunta principal do capítulo.

Como o desempenho das redes neurais varia de acordo com os diferentes tamanhos de conjuntos de amostras de combinações paramétricas da descrição do edifício? (pergunta 1)

O desempenho das redes não está diretamente relacionado com o tamanho da amostra, visto que o aumento do tamanho da amostra não necessariamente resultou no melhor desempenho da rede. Outros parâmetros como as combinações das variáveis-chave ou a configuração da arquitetura da rede podem ser tão importantes quanto e alterar os resultados substancialmente. Apesar da mesma distribuição dos parâmetros de entrada, os conjuntos amostrados trataram de amostras independentes, ou seja, é possível que não tenham nenhuma combinação paramétrica em comum. A diferença absoluta entre as três amostras considerando todo o conjunto de treinamento (nesta etapa não foi

utilizado o conjunto “nunca vistos”) não foi expressiva, em especial para parâmetros de energia. Para estes, quanto maior a amostra, menores os erros, inclusive quanto aos desvios observados através do EQM. O conjunto de 100 casos destacou-se dos outros dois pelo pior desempenho referente ao EQM. Em contraste, a Iluminação Natural apresentou tanto erros absolutos quanto desvios menores para a amostra de 100 lux; a diferença entre 200 e 300 casos não foi muito expressiva. Esta variação da amostra de 100 casos perante as outras duas para a iluminação natural pode ter ocorrido devido a características particulares dessa amostra, para a qual o efeito das combinações dos parâmetros no fenômeno pode ter sido mais fácil de ser modelado pelas redes. Em virtude de a média dos erros ser o resultado da média de apenas três RNAs, recomenda-se treinar mais redes e analisar os casos de cada amostra procurando evidenciar as causas para essa diferença entre as variáveis de diferentes naturezas. A análise desses casos enfocando a expectativa de resultados mais significativos a partir do fenômeno a ser modelado deve fornecer indicativos para melhorar o desempenho da rede.

Qual o impacto de diferentes arquiteturas da rede neural para modelar características do desempenho do edifício? (pergunta 2)

O número de neurônios na camada oculta se mostrou fundamental para o desempenho das redes, como pode ser notado nos diversos casos de ajustes de neurônios apresentados. Nenhuma das heurísticas adotadas foi considerada confiável para ser seguida para todos os testes, o que ora funcionou para determinada configuração de rede não se aplicou à outra, como foi o caso das redes DPU para uma só cidade ou para as três cidades.

Com base nas observações das redes com parâmetros de Iluminação Natural e Energia, para 242, 100 e 33 neurônios na camada oculta, pode-se notar que não houve diferença entre a melhor ou a pior configuração de número de neurônios para os parâmetros de diferentes naturezas, o que significa que as redes de configuração que apresentaram o pior desempenho para parâmetros de iluminação foram as mesmas que apresentaram o pior desempenho para parâmetros de energia. Entre as outras duas configurações de redes, destaca-se que a melhor opção para $sDA_{30\%}$ e $sDA_{50\%}$ foi a mesma que para Consumo de Iluminação (33 neurônios), enquanto os demais parâmetros de Iluminação Natural e Energia apresentaram melhor desempenho para a terceira configuração de rede (100 neurônios), embora com pequena diferença com relação à solução anterior.

Qual o efeito do agrupamento ou não de parâmetros de saída de desempenho de diferentes naturezas? (pergunta 3)

O agrupamento dos parâmetros apresentou consequências opostas para parâmetros de iluminação natural e energia quanto ao poder de convergência da rede. Entretanto, para a generalização, o agrupamento foi proveitoso para os parâmetros de ambas as naturezas. No primeiro teste do agrupamento de variáveis de diferentes naturezas, na etapa da escolha do tamanho da amostra, o agrupamento de todas as variáveis de saída foi proveitoso para parâmetros de Iluminação Natural, mas desvantajoso para as variáveis de Energia. O mesmo pode ser observado na etapa seguinte para o conjunto de treinamento, quando foram feitos os testes com a amostra de 200 casos, incluindo a Densidade de Potência em Uso e a Iluminância-alvo. Já para o conjunto “nunca vistos”, assim como a Iluminação Natural, os parâmetros de energia também foram prejudicados pela separação das variáveis.

Como parâmetros de saída de diferentes naturezas são afetados pelos parâmetros de entrada da descrição do edifício? (pergunta 4)

Ao incluir os parâmetros da descrição do edifício Densidade de Potência em Uso e Iluminância-alvo, os erros dos casos “nunca vistos” aumentaram consideravelmente, tanto para parâmetros de saída de iluminação natural quanto para os de energia. Esse aumento nos erros pode ser notado, em especial para consumo iluminação, quando comparado com o mesmo conjunto avaliado na etapa de análise das amostras.

Os parâmetros de entrada da descrição do edifício se apresentaram como os mais críticos para o aprendizado das redes, haja vista os resultados dos conjuntos “nunca vistos” e o detalhamento desses para as redes DPU.

O acréscimo de parâmetros da descrição do edifício em comparação com os testes do Capítulo 5 destaca o aumento da complexidade da análise do fenômeno perante essas interações, fato que fez com que os erros de predição das redes aumentassem consideravelmente.

Como parâmetros de saída de diferentes naturezas são afetados pelos parâmetros de entrada do contexto do edifício? (pergunta 5)

A inclusão dos parâmetros do contexto do edifício (três cidades) tornou as redes ainda mais complexas. Entretanto, foi útil para a convergência das redes (treinamento), embora as redes tenham apresentado maior dificuldade de generalização do conjunto “nunca

vistos”. A maior dificuldade ocorreu para os parâmetros de iluminação natural. Os parâmetros de energia, apesar de terem seu desempenho reduzido com a inclusão das outras duas cidades, apresentaram resultados compatíveis com os resultados de desempenhos mais baixos das redes que consideraram apenas uma cidade.

8. EXEMPLO DE APLICAÇÃO DE RNA PARA MÉTODO SIMPLIFICADO DE PREVISÃO DE ILUMINAÇÃO NATURAL

Este capítulo apresenta uma das possíveis aplicações de redes neurais artificiais para um método simplificado, visando à previsão do potencial do aproveitamento da iluminação natural sob o enfoque do consumo energético. Optou-se pela utilização da rede com o parâmetro Densidade de Potência em Uso para a cidade de Florianópolis, apresentada no Capítulo 7. O método simplificado consiste na proposição de equações para definição de zonas de iluminação natural, baseadas em medidas dinâmicas de iluminação combinadas com o valor da DPU predita pela rede.

8.1 INTRODUÇÃO

Apesar de experimentarmos a iluminação natural todos os dias em nossas edificações, remetendo a um fenômeno simples e cotidiano, a previsão precisa do desempenho de determinada solução de iluminação no desempenho energético é complexa. Muitas normas e códigos reguladores baseiam-se em métodos prescritivos simplificados, que utilizam as difundidas “Regras Práticas”, como a altura da verga para a definição da profundidade da zona de iluminação natural ou o fator de luz diurna, indicado apenas para determinar o desempenho da luz natural no caso de céu encoberto. Entretanto, apesar de as regras colaborarem para a consideração da iluminação natural, ainda são muito limitadas, visto que não diferenciam importantes características da abertura ou das condições dinâmicas de disponibilidade de luz. Essas simplificações dificultam a comparação entre soluções projetuais ou tecnológicas. Ao definir a zona de iluminação natural apenas pela altura da verga, subestimam-se a influência da área total da janela, a orientação, o clima, a localidade, as propriedades de vidro, as proteções solares, as obstruções, o uso do espaço ou das próprias soluções de projeto (HESHONG, 2012).

No contexto de métodos simplificados, pode-se constatar que as RNAs cuidadosamente trabalhadas constituem-se em uma técnica em potencial para ser aplicada na predição da iluminação natural. Como exemplo de aplicação, optou-se por utilizar o parâmetro DPU, pois se acredita que esse parâmetro possa ser utilizado de duas formas: para comparar soluções de iluminação natural, considerando a sua influência no sistema de iluminação artificial; e como dado de entrada para a

simulação termoenergética, viabilizando a integração da simulação para ambientes multizonas. Apesar de as soluções de rede considerando uma cidade com o parâmetro de saída DPU isolado terem apresentado erros elevados para o conjunto “nunca vistos” (até 30% para a rede com 22 neurônios, ver Figura 101), os conjuntos de dados completos apresentaram erros inferiores a 10% para a mesma solução. Além disso, as redes testadas conforme método da literatura apresentaram erros inferiores a 5%, tanto para o conjunto de testes quanto para a avaliação completa das redes. Logo, julgou-se que essa rede poderia ser aprimorada para a aplicação no método simplificado. O método apresentado neste capítulo foi aplicado apenas para a cidade de Florianópolis.

8.2 DETALHAMENTO DO MÉTODO

O método apresentado neste capítulo estrutura-se em dois pilares: a proposição de equações para a determinação de zonas de iluminação natural dinâmicas e a proposição da combinação entre a DPU prevista pela RNA e essas zonas. Vale ressaltar que a DPU corresponde ao percentual da DPI que precisa ser acionada, ou seja, se a DPU é 60%, significa que é necessário acionar apenas 60% da DPI para determinado ambiente em função do aproveitamento da luz natural. Assim, a unidade adotada para a DPU neste trabalho foi $\%h_{DPI}$. Para a determinação da DPU do ambiente todo, pondera-se a DPU encontrada para cada Zona de Iluminação Natural pela DPI (DPU 100%) aplicada ao restante da área. As áreas das Zonas de Iluminação Natural são calculadas em função de cada janela do ambiente individualmente, permitindo que ambientes de formas complexas com diversas configurações de abertura possam ser avaliados.

A Figura 112 mostra a abordagem do método proposto de acordo com o quadro de análise de iluminação natural de Heshong (2011), apresentado na Figura 3, p.61, do capítulo do Método Geral. Destacaram-se em verde escuro os parâmetros abordados por esse método e em verde claro os parâmetros com potencial de serem adicionados a esse método, visto que já foram testados nas RNAs e implementados no algoritmo do Grasshopper, apresentado no Capítulo 7.

Figura 112 – Quadro de análise de iluminação natural, destacando-se o enfoque do método proposto

1	Conforto Humano	+	2	Impactos energéticos	=	A	B	C	D	E	F
	Iluminância Suficiência Distribuição espacial		Energia de Iluminação kWh anual			Descrição do Espaço	Descrição das Aberturas	Informações Climáticas	Contexto Exterior	Comportamento do usuário	Sistemas Energéticos do Edifício
						Geometria Caixas Ortogonais complexas Brise vertical e horizontal	Janelas Tamanho e localização TVIS Envidraçamento difuso	Sol Altitude Azimute	Terreno Refletância difusa Variação sazonal Variação climática	Atividade Tipo de atividade	Iluminação Zonas de controle Dimerização perfilada
			Resfriamento kWh anual			Orientação Cardial Precisão Latitude Longitude	Abertura Zenital Tamanho e localização TVIS	Céu Distribuição Perez	Construções Caixas opacas Refletância difusa	Funcionamento das persianas Acionamento por luminosidade (ofuscamento)	Aquecimento Carga anual
			Aquecimento kWh anual			Propriedades Visuais Refletância difusa Transparência interna	Persianas internas e cortinas Programa operacional	Térmico GDA/GDR Temperaturas horárias Umidade relativa Componente de radiação			Resfriamento Carga anual
						Propriedades Térmicas Transmitância Fator solar (FS)					
						Localização dos sensores Uma ou duas Plano horizontal				Cronograma de uso Tipo de uso Informação/programação horária	

Legenda:
Atendido pelo método
Atendido pelo algoritmo do Grasshopper

Fonte: Adaptado de: Heshong (2011).

8.2.1 Zoneamento de iluminação lateral

Para a proposição de uma equação para determinar o tamanho de uma zona de iluminação natural baseada em medidas dinâmicas, primeiramente se elencaram as variáveis-chave de iluminação que seriam abordadas. Como base teórica, adotou-se a fórmula empírica proposta por Lynes (1979) para a definição do Fator de Luz Diurna Médio para ambientes retangulares iluminados lateralmente, conforme Equação 27.

$$FLD_{\text{médio}} = \frac{A_{\text{janela}} * T_{\text{VIS}} * \theta}{2 * A_{\text{total}} * (1 - R)} \quad (27)$$

Onde:

$FLD_{\text{médio}}$ = Fator de luz diruna médio a ser obtido no ambiente - alvo;

A_{janela} = área da janela;

T_{VIS} = transmissão visível;

θ = ângulo efetivo de céu;

A_{total} = área total de todas as superfícies do ambiente; e

R = refletância média ponderada das superfícies internas do ambiente.

Reinhard e LoVerso (2010) propuseram uma sequência de projeto para iluminação natural difusa baseada em uma combinação de “Regras Práticas” utilizando a mesma fórmula. Nessa sequência, os autores combinaram (i) a definição de $FLD_{\text{médio}}$ alvo e o cálculo do ângulo efetivo de céu (θ); (ii) a aplicação de uma versão refinada do “Estudo de Viabilidade de Iluminação Natural – *Daylight feasibility* – DFF” (O’CONNOR et al., 1997) para a definição de zonas com elevado potencial de atingir o $FLD_{\text{médio}}$ indicado; (iii) a utilização da fórmula de limite de profundidade de Lynes (CIBSE, 1999) (ver Equação 28) e das “Regras Práticas” baseadas na altura da verga para definir dimensões e refletância das superfícies adequadas; e (iv) o cálculo da área de janela necessária para iluminar cada zona, baseado na fórmula do $FLD_{\text{médio}}$ de Lynes (1979). A sequência foi validada através de correlação com simulações no Radiance de $FLD_{\text{médio}}$, apresentando $R^2 = 0.9$. Entretanto, a maior limitação dessa sequência reside justamente no conceito de que essa se sedimenta – a adoção do $FLD_{\text{médio}}$ –, restringindo a sua aplicação à iluminação difusa. Essa solução é útil para determinadas situações, em especial para localidades em que o céu encoberto é predominante, o que não condiz com a realidade brasileira.

$$\left(\frac{\text{Prof}}{L} + \frac{\text{Prof}}{H_{\text{verga}}} \right) > \frac{2}{(1 - R_b)} \quad (28)$$

Onde:

Prof = limite de profundidade do ambiente;

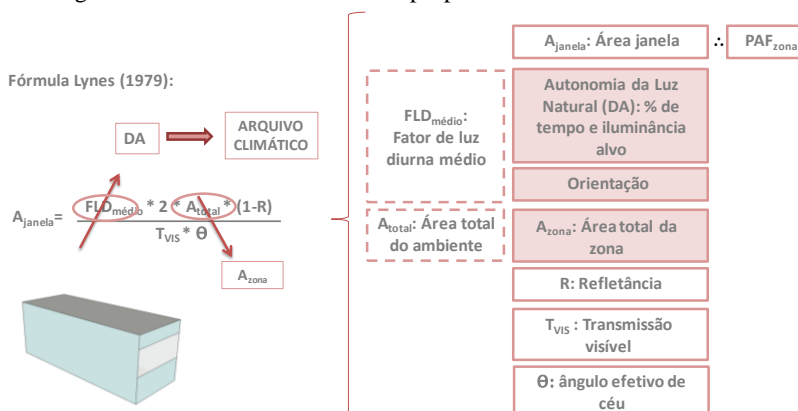
L = largura do ambiente;

H_{verga} = altura da verga; e

R_b = refletância média ponderada das superfícies internas da metade posterior (mais distante da janela) do ambiente.

Diante disso, o procedimento adotado para a proposição de zonas de iluminação natural deste trabalho busca combinar as variáveis-chave da fórmula empírica para determinar o FLD_{médio} de Lynes com as simulações dinâmicas de iluminação natural e regressão multivariada a fim de propor fórmulas para a determinação da profundidade de uma “zona de iluminação natural dinâmica” (ver Figura 113). Foram estabelecidas duas zonas de iluminação natural: Z1 com DA maior igual a 50% (DA ≥ 50%), e Z2 com DA entre 30% e 50% (50% > DA ≥ 30%). Como base, foi adotada a interpretação da fórmula de Lynes, utilizada por Reinhart e LoVerso (2010) no quarto passo da Sequência de Projeto de Iluminação Natural Difusa.

Figura 113 – Partido conceitual da proposta de zoneamento dinâmico



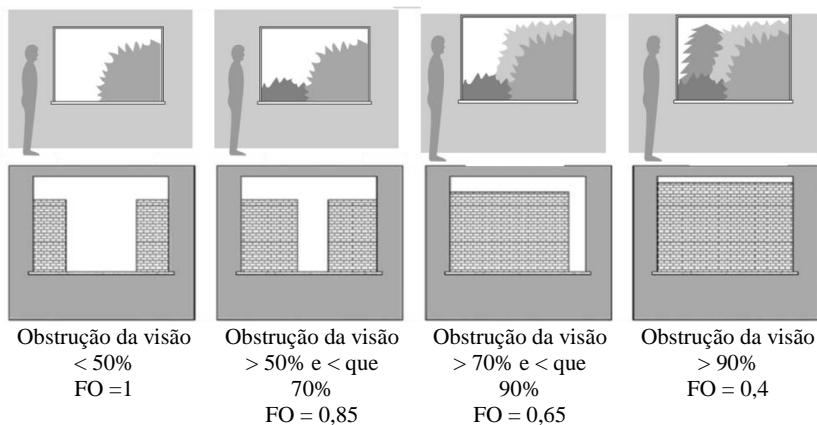
Fonte: Autor.

8.2.1.1 *Definição das variáveis-chave de iluminação natural*

Como variável de desempenho, foi escolhida a Autonomia da Luz Natural Espacial. A adequabilidade da escolha dessa medida pode ser confirmada pelos resultados do estudo conduzido no contexto da *Daylighting Metrics – Task4 of the PIER Daylighting Plus Research Program*, em que a medida foi recomendada para descrever a qualidade visual dinâmica em espaços iluminados naturalmente (HESHONG, 2012). Com base no mesmo documento, a Illumination Engineering Society of North America (2012) publicou o *LM-83-12: Approved Method. Spatial Daylight Autonomy (sDA) and Annual Sunlight Exposure (ASE)*, indicando a mesma medida acompanhada da ASE para identificar a possibilidade de ofuscamento.

Como variáveis de entrada, foram escolhidas as mesmas utilizadas por Lynes, ilustradas na Figura 113, somando-se a Orientação da edificação e a Iluminância de Projeto. Procurou-se selecionar valores que abrangessem o mínimo e o máximo para PAF e T_{VIS} . As Iluminâncias de Projeto foram escolhidas considerando-se um valor baixo, 100 lux (por exemplo, áreas de circulação); um valor intermediário, 300 lux (antiga NBR 5413 para escritório); e um valor alto, 500 lux (nova NBR ISO/CIE 8995-1 para escritórios). Foram considerados dois conjuntos de combinações de refletância interna e as quatro orientações cardeais. Além disso, um Fator de Obstrução (FO) igual a 1 foi adotado a fim de representar uma obstrução fixa para modelar a influência da obstrução de um entorno teórico, visto que grande parte dos ambientes terá algum tipo de obstrução, mesmo que mínima, quando considerado um contexto urbano hipotético. De acordo com a Figura 114, o Fator de Obstrução igual a 1 equivale a uma visão obstruída em 50% ou menos (O'CONNOR et al., 1997).

Figura 114 – Relação entre o percentual de obstrução de visão do entorno e o FO



Fonte: Adaptado de: Reinhard e LoVerso (2010) e O'Connor et al. (1997).

A Tabela 19 resume os valores atribuídos a cada variável-chave utilizada para a simulação da iluminação natural.

Tabela 19 – Valores atribuídos às variáveis-chave para as simulações do zoneamento de iluminação natural para aberturas laterais

Variável	Opções	Quantidade
Ambiente	Retangular (3x8x3 m) / área = 28 m ²	1
PAF	20%	4
	40%	
	60%	
	80%	
Forma da Abertura	Retangular; em fita de lateral a lateral do ambiente; verga 2,10 m	1
Transmissão visível do vidro	20%	4
	40%	
	60%	
	80%	
Iluminância de projeto	100 lux	3
	300 lux	
	500 lux	
Pé-direito	Simple (3 m)	1
Zona bioclimática (ZB)	ZB 3 – Florianópolis: -27° 35' 48"S/ -48° 32' 57"W	1
Refletância média	40% (piso 20%; parede 40%; teto 60%).	2
	60% (piso 30%, parede 60%; teto 80%).	
Orientação	N, S, L, O	4
Fator de Obstrução (FO)	1 (visão externa obstruída em 50% ou menos)	1
Total		384

Fonte:Autor.

8.2.1.2 Simulação da iluminação natural

A modelagem dos ambientes foi feita no programa SketchUp, e a simulação anual de iluminação natural foi feita no programa Daysim. Utilizou-se o arquivo climático, considerando as 8.760 horas do ano para a cidade de Florianópolis. O horário de ocupação foi considerado o horário comercial, das 08:00h às 18:00h apenas nos dias de semana. Os parâmetros de entrada do Radiance foram adotados segundo a Tabela 20.

Tabela 20 – Parâmetros do Radiance para a simulação de iluminação natural para as simulações do zoneamento de iluminação natural

Inter-reflexões difusas do ambiente	Divisão do ambiente	Amostragem do ambiente	Precisão do ambiente	Resolução do ambiente	Limiar direto	Amostragem direta
5	1000	20	0,1	300	0	0

Fonte: Adaptado de: Reinhart (2012).

O Daysim utiliza uma malha de pontos, definida pelo simulador que caracteriza os pontos no plano de análise em que serão lidos os valores de Autonomia da Luz Natural (DA). Foram calculados os valores de DA para 50% do tempo e para 30% do tempo. Da mesma forma que nas simulações de iluminação natural do Capítulo 7, a malha foi alocada a 0,75 m do piso, altura do plano de trabalho. Os pontos distanciaram-se 50 cm uns dos outros em ambos os sentidos.

Os resultados das simulações utilizadas para a proposição das equações de profundidade e de largura da zona Z1 e da zona Z2 ainda foram tabulados e comparados com as “Regras Práticas” da Title 24 (CALIFORNIA ENERGY COMMISSION, 2013); da CIBSE (1999); e com o Passo 3 da Sequência de Projeto de Iluminação Natural Difusa de Reinhart e LoVerso (2007).

8.2.1.3 *Proposição de equações dinâmicas para o cálculo da área das zonas*

A proposta de cálculo da área das zonas abrangeu equações para a determinação da profundidade e da largura das zonas. Para a proposição das equações da profundidade das zonas, a Autonomia da Iluminação Natural Espacial foi abordada relacionando os resultados de DA obtidos através das simulações, combinados com a profundidade que atingiam nos modelos. Para a proposição das equações dinâmicas verificou-se a curva de tendência resultante da dispersão dos valores de Autonomia de Iluminação Natural resultante das simulações, sendo a curva exponencial a que apresentou melhor correlação dos dados. Considerou-se que a regressão multivariada não linear tradicional, baseada em métodos estatísticos, poderia permitir a consideração dos outros parâmetros arquitetônicos julgados importantes para a definição mais precisa da profundidade da zona, mantendo o caráter simplificado e priorizando a velocidade de reposta.

Os resultados das simulações foram compilados e correlacionados com as variáveis independentes através de regressão não linear multivariada, que retorna os parâmetros de uma tendência exponencial. As equações foram elaboradas utilizando-se planilha Excel por meio da função PROJ.LOG, descrita pela Equação 29, tal como

$$y = (b * (m_1^{x_1}) * (m_2^{x_2}) * \dots) \quad (29)$$

Onde:

y = variável dependente;

b = constante;


m = bases de x ; e

x = variável independente.

O valor dependente y é uma função dos valores independentes x . Os valores m são as bases correspondentes a cada valor de expoente x , e b é um valor constante. Na análise de regressão, essa função calcula uma curva exponencial que ajusta os dados e retorna uma matriz de valores que descreve a curva. Salienta-se que y , x e m podem ser vetores (MICROSOFT, 2007).

Logo, a variável dependente y , ora foi correspondente à zona Z1 ($DA \geq 50\%$), e ora à Z2 ($50\% > DA \geq 30\%$). Como os modelos adotados são retangulares com janelas em fita, os valores de DA resultantes das simulações tendem a ser próximos para pontos da mesma linha, quando analisados de uma lateral a outra do modelo. Dessa forma, optou-se por se utilizarem os pontos da linha média no sentido da profundidade de cada modelo como referência de DA por profundidade de cada zona (ver Figura 115).

Figura 115 – Exemplo de representação gráfica do zoneamento



Fonte: Autor.

Determinou-se a profundidade de cada zona para cada modelo, e esses dados foram utilizados como dado de variável dependente das regressões. O valor da profundidade do ambiente foi utilizado posteriormente para o cálculo da área total da zona. A área total do ambiente utilizada na fórmula de Lynes corresponde à soma da área de todas as superfícies que o envolvem. Logo, para a adaptação da fórmula de Lynes para uma equação que retornasse a profundidade da zona, duas substituições conceituais foram feitas: a substituição do $FLD_{\text{médio}}$ por um DA_{alvo} e a área do ambiente pela área da zona em que este DA_{alvo} era alcançado.

A relação das variáveis independentes da equação, se localizadas no numerador ou no denominador, por exemplo, respeitou a equação analítica de Lynes. Para chegar à substituição do $FLD_{\text{médio}}$ da equação pelo DA_{alvo} , primeiramente, aplicou-se a regressão exponencial considerando-se exatamente as mesmas variáveis de Lynes, inclusive o $FLD_{\text{médio}}$. Em seguida, substituiu-se o $FLD_{\text{médio}}$ pelo $DA_{\text{médio}}$ do ambiente. Como terceiro passo, adotou-se o $DA_{\text{médio}}$, substituindo a área do ambiente pela área da zona; e por fim substituiu-se o $DA_{\text{médio}}$ pelo DA_{alvo} , mantendo-se a área da zona. Este processo foi realizado considerando-se apenas a profundidade atingida pela zona Z2 ($Z1+Z2$).

Estes testes iniciais das equações foram realizados para os seguintes conjuntos de dados:

- utilizando todos os modelos simulados;
- excluindo os modelos com PAF 80%, por possuírem área de abertura abaixo do plano de trabalho; e
- separando modelos com diferentes iluminâncias de projeto em equações diferentes.

Diante dos resultados obtidos ainda foram geradas mais uma série de testes considerando apenas a combinação DA_{alvo} e área da zona:

- separando modelos com diferentes PAFs em equações diferentes; e
- separando modelos com diferentes orientações em equações diferentes.

Por fim, o conjunto de dados que ofereceu equações com melhor desempenho foi utilizado para gerar também as equações para a zona Z1. Para cada solução, foram avaliados o coeficiente de determinação R^2 e a soma dos resíduos. Esses parâmetros foram utilizados para a escolha das equações a serem adotadas.

A fórmula de Lynes não fornece diretamente a profundidade da zona; logo, a variável dependente adotada foi $2 \cdot \text{Área da Zona}$. Esse resultado é usado na Equação 30, baseada no cálculo da área de todas as

superfícies de um paralelepípedo retângulo para retornar a profundidade da zona.

$$Prof_{ZONA} = \frac{A_{ZONA} - [2 * (L_{ZONA} * H_{ZONA})]}{2 * (L_{ZONA} + H_{ZONA})} \quad (30)$$

Onde:

Prof_{zona} = profundidade da zona;

A_{zona} = área total de todas as superfícies da zona;

L_{zona} = largura da zona; e

H_{zona} = altura da zona (pé-direito útil).

As simulações utilizadas para a determinação das equações de profundidade basearam-se em modelos com janela em fita, visando isolar essa variável. Dessa forma, essas simulações não permitem a observação da influência da iluminação natural para as laterais da janela. Assim, para a definição da largura das zonas, foram feitas novas simulações para os dois tamanhos de janelas. Para tal, as distâncias entre as arestas da janela e as paredes perpendiculares são iguais para os dois lados da janela. Essas simulações foram feitas para as duas zonas, considerando 300 lux e 500 lux como iluminância-alvo. O alcance das zonas foi computado, e buscaram-se, analiticamente, relações geométricas das variáveis arquitetônicas do espaço que pudessem expressar a dimensão que cada zona deveria ter no sentido paralelo à janela.

As janelas possuem a mesma altura de verga (2,4 m); a janela 1 (J1) não possui peitoril e a janela 2 (J2) apresenta peitoril médio com 1m de altura. A janela 1 possui 2,25 m de largura, enquanto a janela 2 possui a metade da largura (1,125 m). Com isso, buscou-se avaliar duas tipologias de janelas, variando altura de peitoril e largura.

Como malha de pontos de medição de DA, adotou-se a malha sugerida pelo programa, distribuindo os pontos homogeneamente pelo plano de análise. Os mapas de DA gerados foram analisados e as áreas correspondentes à zona Z1 (DA ≥ 50%) e à zona Z2 (50% > DA ≥ 30%) foram delineadas.

Para a obtenção de uma equação que fornecesse a largura da zona, precisou-se de um índice que viabilizasse a obtenção de uma equação comum às janelas (i_{LZ}). Para isso, foram testadas algumas relações: (i) média das larguras da zona/larguras do vão; (ii) altura do

vão/largura da janela; (iii) altura da verga/largura da janela; (iv) largura da zona/área da janela; (v) (largura da zona/área da janela)/altura da verga; e, por fim, (vi) (altura da verga*largura da janela)/largura da zona para um lado da aresta da janela. A relação que melhor representou a largura da zona para os casos simulados foi a relação utilizada para a obtenção de um índice de largura da zona (i_{LZ}).

8.2.2 Proposição do uso da RNA para previsão da DPU para Florianópolis

Com a intenção de que o método simplificado pudesse ser utilizado em ambientes de geometrias variadas e com diferentes quantidades e distribuições de janela, optou-se por considerar a DPU aplicada a cada zona. Cada zona corresponde a uma janela. No caso de mais de uma janela em que as zonas se sobreponham, optou-se por priorizar a zona correspondente à maior abertura.

A DPU da Zona Z1 corresponde à DPU fornecida pela RNA; logo, os parâmetros de entrada relativos à dimensão da zona utilizados como entrada para a RNA devem corresponder aos obtidos para a Zona Z1 através do cálculo proposto para o zoneamento.

A DPU da Zona Z2 corresponde à DPU obtida pela RNA para a Zona Z1, multiplicada pelo Fator de Ajuste de DPU, pois as simulações utilizadas para o treino da rede neural consideraram a DPU do modelo de maneira geral, não sendo possível determinar DPUs separadas por zonas. O Fator de Ajuste de DPU foi determinado através dos valores de DA observados nos modelos do zoneamento; calculou-se o DA médio de cada zona para cada ambiente, determinando-se uma proporção média entre as zonas. Definidas as dimensões das zonas e suas respectivas DPUs, ponderaram-se as DPUs pelas respectivas áreas e pela DPI do restante do ambiente (área não atingida pelas zonas de iluminação natural).

Esse zoneamento pode ser utilizado para a orientação do projeto luminotécnico, em especial para a definição dos circuitos de iluminação e o posicionamento de sensores de iluminação natural.

Para descrever a sequência de aplicação do método, foi elaborado um exemplo de aplicação. A sequência é apresentada no item 8.3.2, p. 338, e descreve em quatro passos como utilizar as equações e as relações propostas para a definição da DPU do ambiente.

8.3 RESULTADOS

Serão apresentados primeiramente os resultados da proposição do zoneamento, em seguida os resultados da definição do Fator de Ajuste de DPU e, por fim, a aplicação do zoneamento em conjunto com a DPU.

8.3.1 Zoneamento de iluminação lateral

Para a definição de um zoneamento dinâmico de iluminação natural, estabeleceram-se dois métodos: um para definir a profundidade e outro para definir a largura da zona, os quais terão seus resultados apresentados nos itens a seguir.

8.3.1.1 *Equações dinâmicas para a definição da profundidade das zonas*


Inicialmente, os resultados das 384 simulações de iluminação natural foram tabulados e plotados em mapas médios de DA, permitindo a identificação da diferença dos tamanhos das zonas por orientação. A Figura 116 ilustra uma média entre os zoneamentos, considerando 300 lux e 500 lux.

Esses mapas permitem comparar a diferença do tamanho das zonas entre uma orientação e outra. Em média, a diferença do tamanho de zonas por orientação, quando as demais características foram fixadas, variou entre 0,5 m e 1 m de profundidade. Esse resultado salienta a necessidade de métodos simplificados sensíveis às diferentes orientações para a estimativa de luz natural, em especial para locais em que a frequência de ocorrência de céu totalmente encoberto não é predominante e essa variação é mais percebida.

Observada a variação dos PAFs na mesma figura, os modelos com 20% de abertura foram os que apresentaram maior diferenciação quanto à forma e à ocorrência das zonas, sendo Z1 praticamente inexistente para a orientação Sul. Os demais PAFs apresentam proporções parecidas para Z1 e Z2; e, naturalmente, as zonas vão atingindo maior profundidade conforme o PAF aumenta.

Entretanto, é importante salientar que todos os modelos, apesar de PAFs diferentes, possuem a mesma altura da verga, o que indica que a simplificação da adoção da altura da verga como único parâmetro para definição da profundidade da zona de iluminação natural pode levar a imprecisões significativas ao determinar a profundidade da zona sem considerar a área real de captação de luz.

Figura 116 – Mapas médios de zoneamento (300 e 500 lux) separados por PAF e orientação

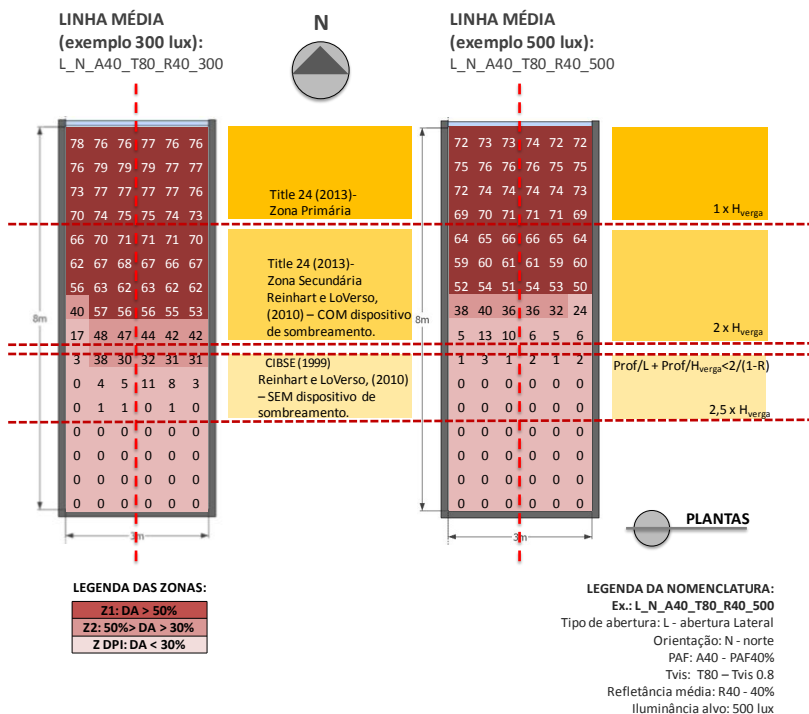


Fonte: Autor.

A Figura 117 mostra dois modelos orientados a Norte, com PAF 40%, T_{VIS} 80%, conjunto de refletância média de 40% e sem proteção solar para 300 lux e 500 lux. O modelo foi escolhido de forma a representar uma zona média e de ocorrência frequente em edificações, priorizando a transmissão visível do vidro simples e um percentual de abertura intermediário. Nessa imagem foram salientadas três medidas de “Regras Práticas”: as zonas primária (Z1) e secundária (Z2), baseadas na Title 24 (CALIFORNIA ENERGY COMMISSION, 2013); o limite de profundidade da CIBSE (1999); e as zonas de iluminação natural para ambientes com e sem sombreamento, salientadas no Passo 3 da Sequência de Projeto de Iluminação Natural Difusa, de Reinhart e LoVerso (2007). A zona secundária da Title 24 coincide com a zona de iluminação natural para ambientes com sombreamento, proposta por Reinhart e LoVerso (2007) e ultrapassada em 25 cm pelo limite da zona da CIBSE (1999). Os autores propuseram as fórmulas de alcance de iluminação natural baseando-se em uma série de simulações anuais de

iluminação natural, realizadas para cinco cidades norte-americanas, descritas em um estudo anterior de Reinhart (2005). Neste estudo, Reinhart (2005) comparou diferentes “Regras Práticas” e propôs, também baseado em autonomia da luz natural, as relações de profundidade em relação à altura da verga, salientadas na Figura 117. Para os modelos por ele estudados, a maior frequência de ocorrência de limites da zona de iluminação natural sucedeu para a profundidade de 1 vez a altura da verga no caso de 500 lux e 1,5 vez a altura da verga para 300 lux.

Figura 117 – Representação gráfica dos modelos indicando onde passa a linha média e o cruzamento das profundidades das zonas com os limites estabelecidos pelas “Regras Práticas”



Fonte: Autor.

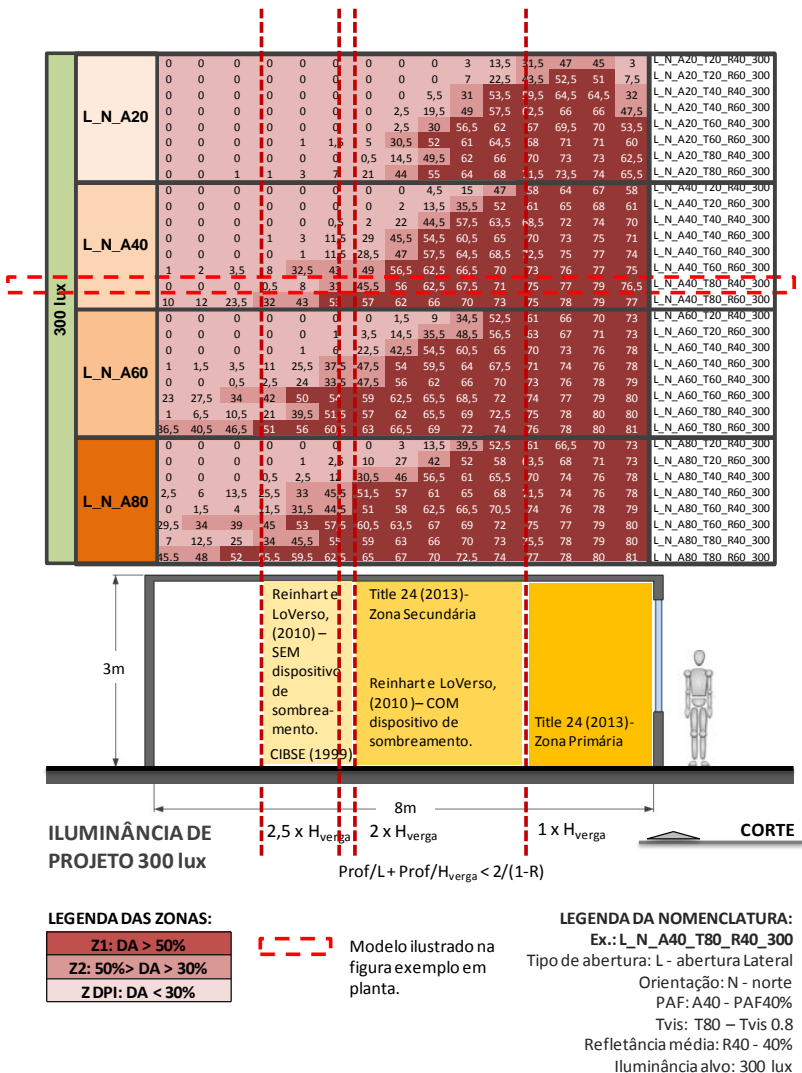
Essa comparação demonstra a importância da não generalização dessas fórmulas, mesmo nas etapas iniciais de projeto. Na Figura 117, pode-se notar a diferença significativa entre as zonas 1 e 2 simuladas

para a cidade de Florianópolis, tanto para 300 lux quanto para 500 lux. Por vezes, as “Regras Práticas” apresentadas subestimam e, por vezes, superestimam a profundidade da zona.

Ainda na Figura 117, foi destacada uma Linha Média nos modelos. Essa linha foi utilizada para a determinação da profundidade de cada zona para cada modelo. O resultado obtido no levantamento dos valores de DA por posição na linha serviram como dado de referência para o desenvolvimento das equações de regressão.

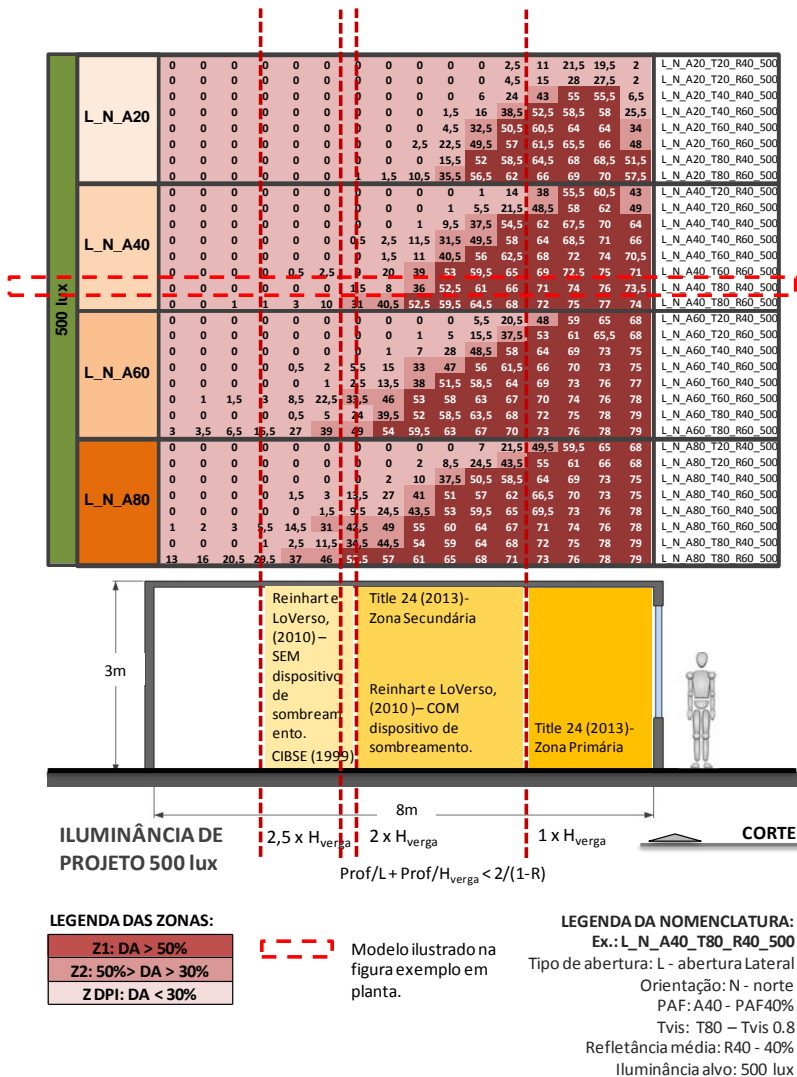
A Figura 118, a Figura 119 e a Figura 120 mostram uma tabela adaptada em que cada linha corresponde aos valores de DA obtidos através da Linha Média para 300, 500 e 100 lux, respectivamente. Nessas imagens, o quadro tracejado vermelho destaca o que corresponderia a uma Linha Média referindo-se aos mesmos modelos apresentados em planta na Figura 117. O código à esquerda exibe as informações de cada modelo (ver legenda do código na Figura 117). O código na coluna da direita indica o tipo de iluminação, no caso lateral (L), a orientação (N), o PAF utilizado (AXX), a T_{VIS} (TXX), a refletância (RXX) e a iluminância de projeto (300). O corte logo abaixo indica a posição da janela. E as linhas bordô na vertical indicam as três marcações das “Regras Práticas”, já apresentadas em planta na Figura 117.

Figura 118 – Valores de DA por modelo na linha média para iluminância de projeto de 300 lux e cruzamento das profundidades das zonas com os limites estabelecidos pelas “Regras Práticas”



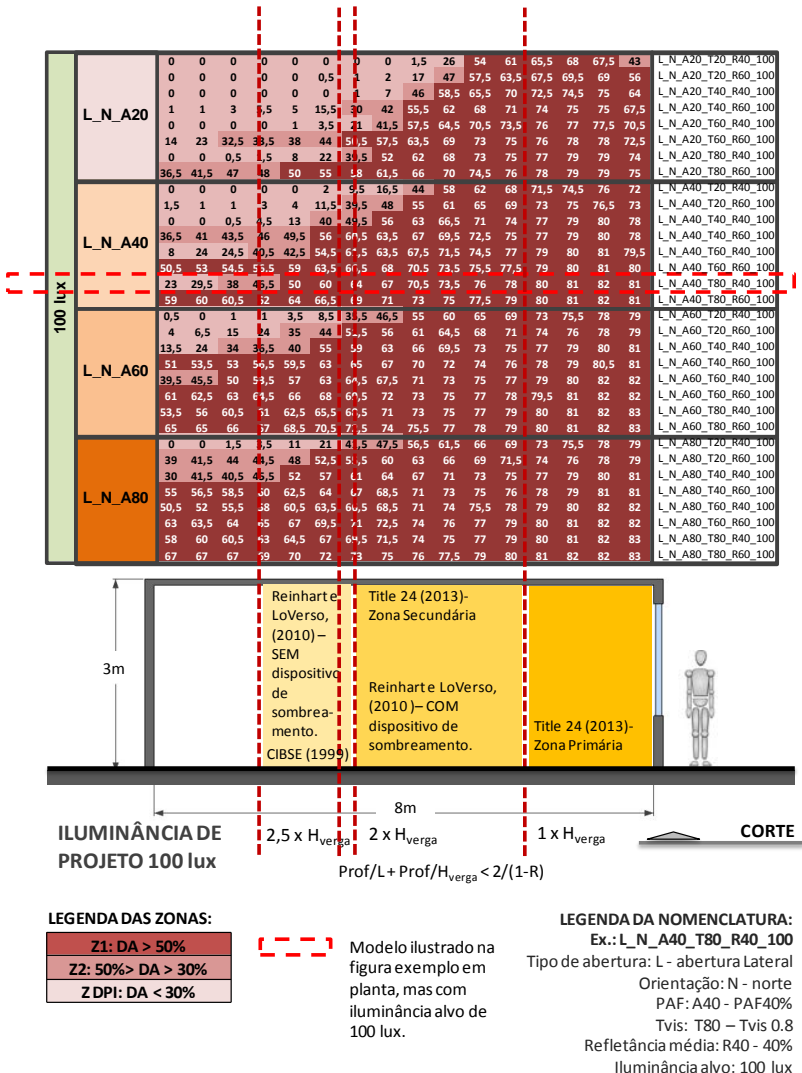
Fonte: Autor.

Figura 119 – Valores de DA por modelo na linha média para iluminância de projeto de 500 lux e cruzamento das profundidades das zonas com os limites estabelecidos pelas “Regras Práticas”



Fonte: Autor.

Figura 120 – Valores de DA por modelo na linha média para iluminância de projeto de 100 lux e cruzamento das profundidades das zonas com os limites estabelecidos pelas “Regras Práticas”



Fonte: Autor.

Nesses cortes é possível ver a grande diferença entre profundidade alcançada para cada configuração de modelo. Nota-se

ainda a grande diferença de quando se consideram diferentes iluminâncias-alvo. No caso da consideração de 100 lux, por exemplo, para aberturas com PAF 60% e 80%, a Z1 chegou a ocupar os 8 m de profundidade dos ambientes simulados (ver Figura 120). Logo, julgou-se importante considerar equações de regressão incluindo iluminância-alvo como uma das variáveis independentes da equação.

Com base nessas observações, algumas adaptações foram feitas para a proposição das equações. Como as equações para iluminância de 100 lux ficariam limitadas aos 8 metros de profundidade dos modelos (ver Figura 120) e não representariam bem o potencial de alcance da iluminação natural, os resultados das simulações considerando iluminância-alvo 100 lux foram excluídos da regressão. Alguns testes quanto à forma mais adequada de considerar as variáveis na equação foram realizados. Para a Orientação, foram testados os valores em graus, em ângulo e em radianos; entretanto, a opção em graus apresentou os menores erros.

A Tabela 21 traz os resultados de coeficiente de determinação (R^2) e soma dos quadrados dos resíduos (SQR) para etapas da substituição do $FLD_{\text{médio}}$ da equação de Lynes pelo DA_{alvo} . Estes resultados mostraram que as variações testadas foram pouco expressivas quanto ao R^2 , resultando em alterações apenas nas terceiras e quartas casas decimais. Já a SQR apresentou variações significativas. Avaliando-se as equações com as “mesmas variáveis de Lynes”, aplicadas à regressão exponencial (primeira coluna), a subdivisão do conjunto de dados em iluminâncias alvo de 300 lux e 500 lux e a desconsideração dos resultados de PAF 80% permitiu a redução do SQR de $7,19\text{m}^2$ para $0,71\text{m}^2$ (variável dependente 2° Área da Zona). Comparando-se o desempenho das equações com as “mesmas variáveis de Lynes” e “ DA_{alvo} e a $\text{Área}_{\text{zona}}$ ” (última coluna), que caracterizam o processo de transformação da fórmula de Lynes (medidas estáticas) para as equações com medidas dinâmicas, considerou-se as equações dinâmicas passíveis de serem exploradas. Isto, porque o resíduo resultante da “ DA_{alvo} e a $\text{Área}_{\text{zona}}$ ” separando-se 300lux e 500lux (última e antepenúltimas linhas) consiste na área de todas as superfícies da zona multiplicada por dois (variável dependente 2° Área da Zona), sendo minimizado ao ser transformado em profundidade da mesma.

Para a opção final com o “ DA_{alvo} e a $\text{Área}_{\text{zona}}$ ” (última coluna), a primeira equação gerada considerou todos os resultados dos modelos simulados para as iluminâncias alvo de 300 lux e 500 lux e devido ao SQR elevado ($18,68\text{m}^2$, variável dependente 2° Área da Zona), julgou-se a amostra ruidosa. A segunda equação baseou-se nas análises dos

mapas das linhas médias (ver Figura 118, p. 328, Figura 119, p. 329, e Figura 120, p. 330) em que a diferença de profundidade das zonas de iluminação natural para PAF 60% e PAF 80% não se mostrou expressiva. Isso porque, neste estudo, a diferença entre as aberturas dos respectivos PAFs se dá apenas com a variação do peitoril. No caso do PAF 80%, a área de abertura que se tem a mais do que o PAF 60% está localizada abaixo da altura do plano de trabalho, no qual está localizada a malha de sensores que medem os valores de iluminância utilizados para o cálculo da autonomia da luz natural. Com isso, o segundo teste foi feito excluindo os modelos com PAF 80% do conjunto utilizado para a regressão. Como consequência, o SQR diminuiu para 14,86 m² (variável dependente 2*Área da Zona). A separação dos conjuntos de iluminância alvo 300 lux e 500 lux desconsiderando PAF 80% reduziu o SQR em aproximadamente 50% para ambas os conjuntos de iluminâncias alvo, quando comparado à solução anterior.

Tabela 21 – Resultados de R² e SQR para as etapas da adaptação da equação de Lynes para a substituição do FLD_{médio} por DA_{alvo} nas equações dinâmicas

Comparação da fórmula de Lynes com as aplicações da regressão logarítmica:		Mesmas variáveis de Lynes	Substit. FLD _{médio} por DA _{médio}	DA _{médio} e Área _{ambiente} substituída por Área _{zona}	DA _{médio} substituído por DA _{alvo} e Área _{zona}
Todos os modelos (300 lux e 500 lux)	R ²	0,9983	0,9966	0,9963	0,9964
	SQR (m ²)	7,19	14,01	19,12	18,68
Excluindo os modelos com PAF 80% (300 lux e 500 lux)	R ²	0,9995	0,9994	0,9966	0,9960
	SQR (m ²)	1,42	1,99	12,67	14,86
Separando o conjunto anterior – 300 lux	R ²	0,9995	0,9994	0,9993	0,9968
	SQR (m ²)	0,71	0,90	1,45	6,31
Separando o conjunto anterior – 500 lux	R ²	0,9995	0,9994	0,9963	0,9955
	SQR (m ²)	0,71	0,99	6,45	7,75

Fonte: Autor.

Os outros testes que se seguiram abordaram a separação dos conjuntos de iluminância-alvo 300 lux e 500 lux em subconjuntos separados por PAFs e posteriormente, a separação destes últimos por orientação. Para as equações separadas por PAFs, reconsideraram-se as equações com PAF 80%. A separação por orientação se deu mais em

caráter investigativo para possibilitar a avaliação do impacto dessa variação; do contrário, a subdivisão excessiva dos conjuntos resultaria em um método fragmentado com muitas equações. Os testes com orientação foram feitos para todos os casos, os de PAF 20% foram escolhidos a título de ilustração. A melhora nos resultados foi equivalente à exposta na Tabela 22.

Os conjuntos escolhidos para a proposição de equações para a zona Z1 e para o exemplo que será apresentado no item 8.3.2, p. 338, foram aqueles referentes aos conjuntos separados por iluminância de projeto e por PAF. A escolha se deu com base na opção por SQRs menores que 1m^2 (variável dependente $2 \times \text{Área da Zona}$) para todos os PAFs, com exceção do PAF 20%. Todas as equações propostas são apresentadas no APÊNDICE F, p. 445.

Tabela 22 – Resultados de R² e SQR para as diferentes opções de equações testadas

TESTE DE COMBINAÇÕES		R ²	SQR (m ²)
ZONA Z2: DA 30% (Z1+Z2)	Conjunto 300 lux separado por PAF: PAF 20%	0,9919	4,57
	Conjunto 300 lux separado por PAF: PAF 40%	0,9997	0,19
	Conjunto 300 lux separado por PAF: PAF 60%	0,9996	0,29
	Conjunto 300 lux separado por PAF: PAF 80%	0,9994	0,42
	Conjunto 500 lux separado por PAF: PAF 20%	0,9935	3,02
	Conjunto 500 lux separado por PAF: PAF 40%	0,9987	0,78
	Conjunto 500 lux separado por PAF: PAF 60%	0,9995	0,31
	Conjunto 500 lux separado por PAF: PAF 80%	0,9990	0,67
	Conjunto 300 lux, PAF 20% – separado por orientação: Norte	0,9991	0,13
	Conjunto 300 lux, PAF 20% – separado por orientação: Sul	0,9908	1,19
	Conjunto 300 lux, PAF 20% – separado por orientação: Leste	0,9987	0,19
	Conjunto 300 lux, PAF 20% – separado por orientação: Oeste	0,9927	1,01
	ZONA Z1: DA 50%	Conjunto 300 lux separado por PAF: PAF 20%	0,9917
Conjunto 300 lux separado por PAF: PAF 40%		0,9990	0,65
Conjunto 300 lux separado por PAF: PAF 60%		0,9996	0,27
Conjunto 300 lux separado por PAF: PAF 80%		0,9993	0,47
Conjunto 500 lux separado por PAF: PAF 20%		0,9916	3,30
Conjunto 500 lux separado por PAF: PAF 40%		0,9943	3,12
Conjunto 500 lux separado por PAF: PAF 60%		0,9993	0,42
Conjunto 500 lux separado por PAF: PAF 80%		0,9990	0,65


Fonte: Autor.

A Figura 121 e a Figura 122 trazem um comparativo entre os valores simulados da variável dependente 2*Área da Zona e os valores equacionados para as equações referentes ao grupo de 300 lux e ao grupo de 500 lux, respectivamente. No caso das equações para iluminância-alvo de 300 lux, pode-se notar que os valores equacionados

são levemente maiores que os simulados, em especial para os modelos que permitem maior admissão de luz (maiores T_{VIS} e Refletância) para as equações para PAF 20% e PAF 40%. Já para PAF 60%, esses mesmos modelos tiveram seus resultados subestimados pelo equacionamento.


Considerando-se o grupo de 500 lux (ver Figura 122), pode-se notar uma superestimação dos resultados por parte das equações de PAF 20%. Por outro lado, as equações de PAF 40% e PAF 60% têm os valores dos modelos com menor admissão de luz superestimados.

Figura 121 – Comparação dos valores simulados e calculados através das equações para 300 lux separadas por PAF



Fonte: Autor.

Figura 122 – Comparação dos valores simulados e calculados através das equações para 500 lux separadas por PAF



Fonte: Autor.

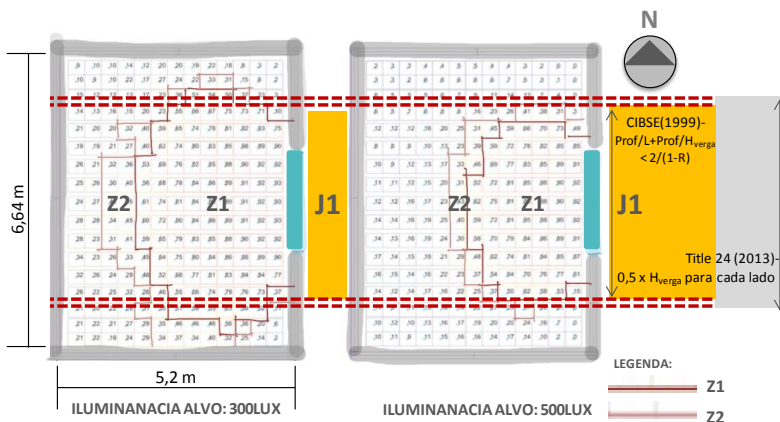
8.3.1.2 Formulação analítica para a definição da largura das zonas

Para a definição de uma zona de iluminação natural, além da profundidade da zona, foi preciso definir a largura da zona. A Sequência de Projeto de Iluminação Natural Difusa, de Reinhart e LoVerso (2010),

possibilita a definição da largura da zona de iluminação natural indiretamente através do uso da fórmula da CIBSE (1999), já apresentada na Figura 117 à Figura 120. A Title 24 (CALIFORNIA ENERGY COMMISSION, 2013) sugere que para zonas em ambientes com ou sem sombreamento a largura da zona deve ser considerada 0,5 vez a altura da verga para cada lado da janela, medida a partir das arestas da janela. De acordo com a fórmula da CIBSE (1999), apresentada na Equação 28, a largura da zona para J1 seria 4,5 m e para J2 seria 3,08 m, enquanto, para a Title 24, a largura da zona para J1 seria 4,65 e para J2 seria 3,5.

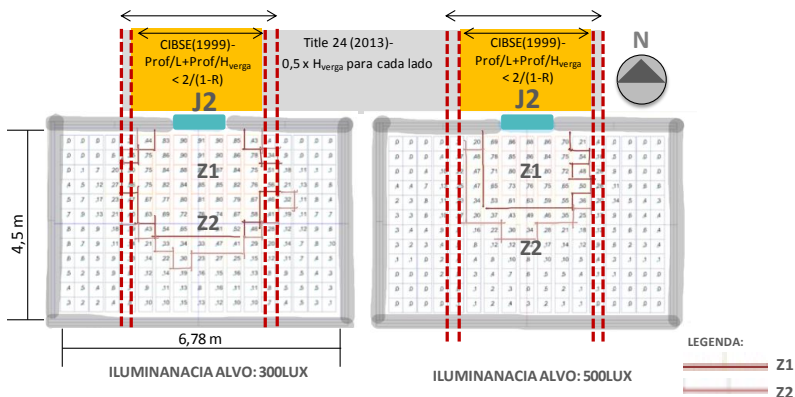
A Figura 123 e a Figura 124 mostram o zoneamento traçado para as quatro configurações descritas, com as marcações de linhas tracejadas em bordô dos limites da Title 24 (CALIFORNIA ENERGY COMMISSION, 2013); e da CISBE (1999). Essa avaliação permitiu constatar que o dimensionamento sugerido pelas “Regras Práticas” abordadas aproxima-se as das zonas obtidas por simulação para ambas as opções de área de janela (J1 e J2). Contudo, quando se considera iluminância de projeto 300 lux, as zonas tendem a ultrapassar os limites adotados pelas regras práticas e, quando considerada iluminância de 500 lux, as regras tendem a superdimensionar a zona.

Figura 123 – Representação da determinação da largura da zona em planta e cruzamento das larguras-limite estabelecidas pelas “Regras Práticas” – Janela 1



Fonte: Autor.

Figura 124 – Representação da determinação da largura da zona em planta e cruzamento das larguras-limite estabelecidas pelas “Regras Práticas” – Janela 2



Fonte: Autor.

Dependendo do tamanho da janela, a variação de quanto as zonas excedem ou subestimam as “Regras Práticas” avaliadas é significativa. A Zona Z2, por exemplo, no caso da maior janela (J1), excede em cerca de 1 m a 2 m os limites de ambas as regras para 300 lux, enquanto que a menor janela (J2) excede em apenas alguns centímetros. Logo, julgou-se necessário encontrar uma fórmula que considerasse o tamanho da janela (fonte de luz), além da altura da verga.

Dentre as relações para a obtenção do índice de largura da zona (i_{LZ}), descritas no item 8.2.1.3, a última relação (vi.: altura da verga * largura da janela / largura da zona para um lado da aresta da janela), foi a que apresentou melhor resultado.

Os i_{LZ} obtidos diferenciam-se por zona e por iluminância de projeto, como mostra a Tabela 23. Apesar de basearem-se apenas em duas configurações de janela e espaço, como as proporções das janelas abarcam janelas de proporções diferentes e diante da menor variação da iluminação natural paralelamente às janelas, acredita-se que o índice possa ser usado. Entretanto, para aplicações futuras, recomenda-se uma validação desse índice através de simulações de mais configurações de janelas. Vale salientar que a J1 possui aproximadamente o dobro de largura que a J2. Os exemplos consideram dois tipos de janelas frequentemente encontrados na arquitetura: sem peitoril e peitoril de 1m.

A Tabela 23 mostra os índices para as zonas Z1, Z2 e Z1+2. Os valores da Z2 foram deixados com menos destaque, pois foram calculados apenas para conferência, visto que levam à dimensão da

largura da zona a partir do fim da Zona Z1 e não da aresta da janela. Para a determinação da largura da Zona Z2, deve-se utilizar a opção Zona Z1+2. O EPAM, comparando-se a aplicação do índice para definir a largura da zona com a largura obtida através de simulação, variou entre 2% (Z1) e 11% (Z2).

Tabela 23 – Valores de índices de largura de zona para cada janela

Combinações	J1	J2	Média
Zona Z1 – 300 lux	0,2370 (0,2)	0,2753 (0,3)	0,2562 (0,3)
Zona Z1 – 500 lux	0,1185 (0,1)	0,1376 (0,1)	0,1281 (0,1)
Zona Z2 – 300 lux	0,1185 (0,1)	0,1376 (0,1)	0,1281 (0,1)
Zona Z2 – 500 lux	0,0593 (0,1)	0,1376 (0,1)	0,0985 (0,1)
Zonas Z1+2 – 300 lux	0,3556 (0,4)	0,4129 (0,4)	0,3843 (0,4)
Zonas Z1+2 – 500 lux	0,1778 (0,2)	0,2753 (0,3)	0,2265 (0,2)

Fonte: Autor.

Diante do exposto, a Equação 31 foi proposta para a determinação da largura da zona para cada lado a partir da aresta da janela e se dá por

$$L_{ZONA} = (H_{VERGA} * L_{JANELA}) * i_{LZ} \quad (31)$$

Onde:

L_{zona} : largura da zona para cada lado a partir da aresta da janela (m);

H_{verga} : altura da verga em relação ao piso (m);

L_{janela} : largura da janela em si (m); e

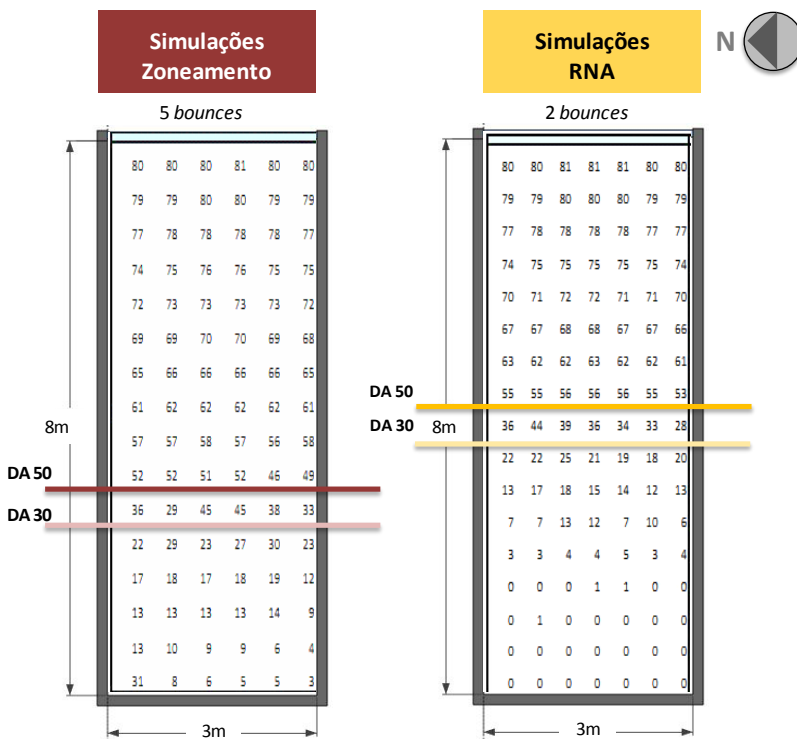
i_{LZ} : índice de largura de zona (adimensional).

8.3.2 Proposição do uso da RNA para previsão da DPU para Florianópolis

Para a proposição da utilização do zoneamento juntamente com a DPU obtida através da rede neural, foi preciso propor uma correção no zoneamento. Devido à consideração do tempo e do volume de simulações, as simulações das RNAs foram realizadas apenas com duas Inter-reflexões Difusas do Ambiente (*bounces*) como parâmetro de

entrada do Radiance (ver Tabela 14, p. 257). Quanto maior o número de *bounces*, maior o refinamento do cálculo, aumentando também o tempo de simulação que cresce exponencialmente conforme a complexidade do modelo. Normalmente, varia-se o número de *bounces* de dois (menos complexos) a sete (mais complexos). Essa diferença resultou, em média, em 1 m a menos para a Z1 no caso das simulações com dois *bounces*, quando comparadas às simulações com cinco *bounces* utilizadas para o zoneamento. A Figura 125 ilustra um dos testes feitos visando avaliar a diferença entre os dois conjuntos de simulação e propor o fator de correção.

Figura 125 – Exemplo de comparação entre os modelos dos dois conjuntos de simulação: com 5 *bounces* e com 2 *bounces*



Fonte: Autor.

Para a definição do fator de correção, o modelo ilustrado na Figura 125 foi simulado para cada orientação cardinal com dois e cinco


bounces. Em seguida, aplicou-se o método do zoneamento para as duas janelas e simularam-se as zonas também com dois e cinco *bounces*. Esses resultados permitiram definir a profundidade das zonas para as duas configurações: a profundidade da zona de dois *bounces* foi subtraída da de cinco *bounces* e calculada a média dessa diferença para todos os modelos do teste. Propuseram-se uma redução de 1 m na Zona Z1 de iluminação natural do zoneamento e nenhuma alteração na Zona Z2. Assim, as regressões apresentadas no item 8.3.1.1, separadas por iluminância de projeto e PAF que foram selecionados para essa proposta, foram refeitas considerando esse ajuste. As regressões consideraram a profundidade atingida pela Zona Z1 e pela Zona Z2 (Zona 1 + Zona 2).

Com a profundidade das zonas simuladas para o zoneamento e para as RNAs compatíveis, foi possível dar continuidade à proposta do método. Como descrito no método (ver item 8.2.2), a RNA prevê a DPU para o modelo simulado de maneira geral. Assim, determinou-se que as dimensões da Zona Z1 seriam utilizadas para obter a DPU através da RNA. Para a determinação da DPU da Zona Z2, dividiu-se o DA médio da Zona Z2 pelo DA médio da Zona Z1. Essa divisão foi feita para os grupos de iluminância-alvo de 100 lux, 300 lux e 500 lux para a orientação Norte, obtidos através das simulações do zoneamento. A média desses resultados foi utilizada para propor o Fator de Ajuste de DPU para a Zona Z2, como mostra a Figura 126. O resultado de 0,6 era esperado, visto que a Zona Z1 considera valores de autonomia da luz natural acima de 50% e a Zona Z2, valores entre 30% e 50% (ver Figura 126a). Como DA 30% equivale a $0,6 \cdot \text{DA } 50\%$, a relação pode ser confirmada. Quanto maior for a diferença entre o $\text{DA}_{\text{médio}}$ da Zona Z1 e o $\text{DA}_{\text{médio}}$ da Zona Z2, menor será o Fator de Ajuste de DPU (DA) para a Zona Z2 (Figura 126b). Para efeito da proposta de método simplificado, adotou-se o inverso do Fator de Ajuste de DPU (DA) para a definição do Fator de Ajuste de DPU da Zona Z2 (FA_{DPU}), obtendo-se 1,6 (ver segunda coluna da Figura 126a). O inverso do Fator de Ajuste de DPU (DA) foi adotado, pois os conceitos são inversos: quanto maior a Autonomia da Luz Natural, menos necessidade de iluminação artificial; e, quanto maior a Percentual da Densidade de Potência em Uso, por mais tempo a iluminação artificial estará acionada.

Figura 126 – Valores para o Fator de Ajuste de DPU para a Zona Z2 e correlação entre FA_{DPU} e a diferença entre $DA_{médio}$ para Z1 e Z2

	Fator de Ajuste de DPU (DA)	Fator de Ajuste de DPU para Zona Z2 (FA_{DPU})
MÉDIA 100 lux	0,6	1,7
MÉDIA 300 lux	0,6	1,7
MÉDIA 500 lux	0,6	1,6
MÉDIA GERAL	0,6	1,6
MÁXIMO 100 lux	0,7	1,9
MÁXIMO 300 lux	0,8	2,1
MÁXIMO 500 lux	0,9	1,9
MÍNIMO 100 lux	0,5	1,4
MÍNIMO 300 lux	0,5	1,2
MÍNIMO 500 lux	0,5	1,2

(a) Fator de ajuste de DPU para Zona Z2



(b) Relação entre FA_{DPU} e a diferença entre $DA_{médio}$ para Z1 e Z2

Fonte: Autor.

8.3.2.1 Resultado da RNA

O método foi testado no modelo apresentado na Figura 123, p. 336, considerando-se o pé-direito de 3 m e a altura da verga de 2,4 m. Para o teste, realizou-se a simulação integrada do modelo no programa DIVA, com os mesmos parâmetros que os utilizados para a simulação no algoritmo do Grasshopper. Esse resultado foi utilizado para a validação do resultado do método simplificado.

Para a obtenção da DPU, treinaram-se RNAs com a mesma configuração de padrões de entrada e saída que as redes apresentadas na ação (3) do item 7.3.4, considerando apenas a cidade de Florianópolis. Entretanto, utilizou-se o método da validação cruzada com $K = 10$

tentativas, com Gradiente Descendente e função logarítmica sigmoideal para a obtenção das redes (esse método foi descrito no item 4.2.2, p. 132). Para a escolha da RNA, compararam-se as 10 RNAs simuladas e escolheu-se a RNA 9. Foram avaliados os desempenhos no treinamento, no teste e na avaliação da zona usada nesse teste (é o caso “nunca visto”). Os resultados de desempenho obtidos para essa rede são apresentados na Tabela 24. Esses resultados foram considerados suficientes, visto que o EPAM de nenhum dos conjuntos ultrapassou 10% e o R^2 da rede foi de 0,9801.

Tabela 24 – Desempenho da RNA 9 para os conjuntos de treino teste e da janela

Referente ao treino		Conjunto de treino simulado pela rede		Conjunto de teste		Zona Z1	
R^2	0,9801	EAM (%h _{DPI})	3,2815	EAM (%h _{DPI})	4,1311	EAM (%h _{DPI})	0,5025
R	0,9892	DesvPad EAM	2,7169	DesvPad EAM	4,7597	EPAM (%)	7,4139
MAE _{NORM}	0,0316	EQM (%h _{DPI})	4,2599	EQM (%h _{DPI})	6,2951		
RMSE _{NORM}	0,0403	EPAM (%)	8,3622	EPAM (%)	9,0490		

8.3.2.2 Exemplo de aplicação do método para um ambiente com uma janela

O método aqui sugerido é composto de quatro passos, apresentados a seguir.

SEQUÊNCIA PARA DETERMINAÇÃO DA DPU DO AMBIENTE

1º PASSO: definir a profundidade das zonas

Para a definição de qual equação utilizar, devem-se determinar primeiro a iluminância-alvo e o PAF. A iluminância-alvo utilizada nesse exemplo será de 500 lux. A determinação do PAF deve ser feita como se a largura da parede coincidissem com a largura da janela. Isso porque os modelos simulados tanto para o zoneamento quanto para a RNA consideraram janelas em fita.

Para o cálculo do PAF, a área de fachada foi considerada o produto entre o pé-direito do ambiente (3 m) e a largura da Janela 1 (2,25 m), resultando em 6,75 m². A área da Janela 1 corresponde a 5,4 m², logo o PAF resultou em 80%. Como as equações selecionadas foram

as separadas por PAFs, conforme item 8.3.1.1, p. 324, adotaram-se as equações para PAF 80%, para Zona Z1 (ver Equação 32) e para Zona Z2 (ver Equação 33). No caso de o PAF resultante não coincidir com nenhuma das equações disponíveis, deve-se escolher a equação para o PAF mais próximo. Como refletância das superfícies, utilizaram-se 20% para piso, 40% para parede e 80% para o teto. Já a autonomia da luz natural a ser alcançada foi de 50% referente ao limite mínimo da Zona Z1 e 30% referente à Zona Z2. Esses dados foram compilados na Tabela 25.

Tabela 25 – Dados de entrada utilizados para as equações da determinação da profundidade das zonas Z1 e Z2

ZONA	PAF (%)	Iluminância-alvo (lux)	T _{VIS}	ORIENTAÇÃO (°)	DA _{MIN} (%)	R _{média}
Z1 (DA 50%)	80	500	0,80	90	50	0,44 (44%)
Z2 (DA 30%)	80	500	0,80	90	30	0,44 (44%)

Fonte: Autor.

A seguir são apresentadas as equações para a Zona Z1 (ver Equação 32) e para a Zona Z2 (Z1+Z2) (ver Equação 33), obtidas conforme item 8.3.1.1. As demais equações estão disponíveis no APÊNDICE F p.445.

$$2 * A_{ZONA} = EXP[(1,3224 * T_{VIS}) + (0,0005 * ORIENT) + \left(178,0858 * \frac{1}{DA_{alvo}}\right) + (0,0019 * \frac{1}{(1 - R)})] \quad (32)$$

$$2 * A_{ZONA} = EXP[(1,3364 * T_{VIS}) + (0,0004 * ORIENT) + \left(113,3518 * \frac{1}{DA_{alvo}}\right) + (0,0015 * \frac{1}{(1 - R)})] \quad (33)$$

Como resultado da aplicação da Equação 32, a Zona Z1 ficou com 2,96 m de profundidade; e, como resultado da aplicação da Equação 33, a Zona Z2 (Z1+Z2) ficou com 4,02 m de profundidade.

2º PASSO: definir a largura das zonas

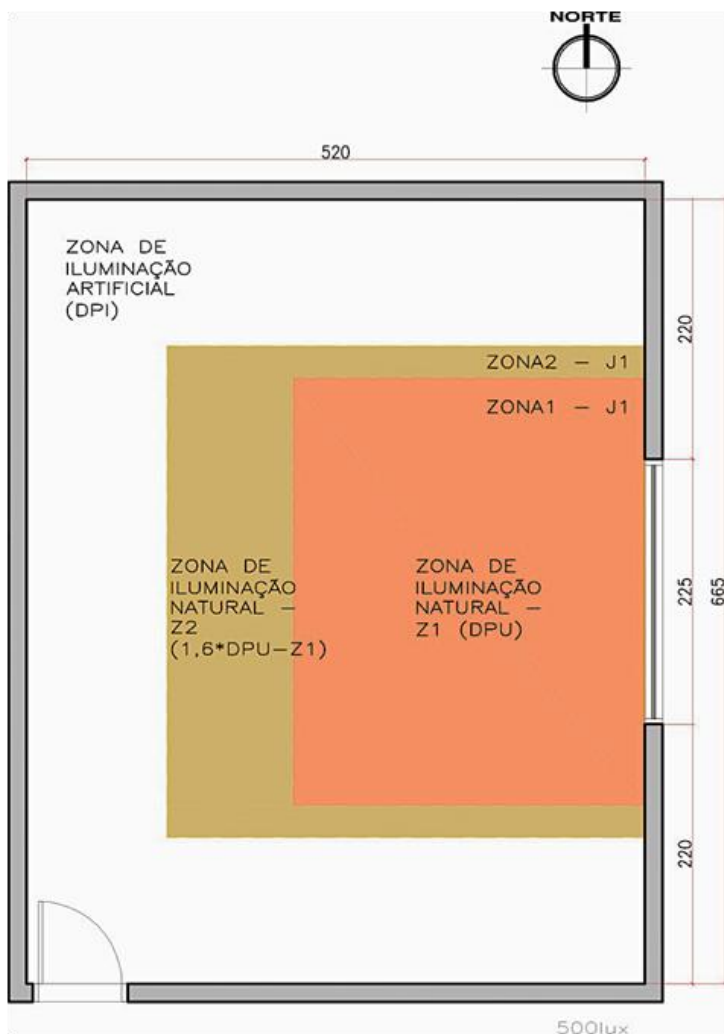
Para a definição das larguras das zonas, aplica-se a Equação 31, p. 338. Os índices de largura de zona (i_{LZ}) utilizados na equação são obtidos de acordo com a Tabela 23, p. 338. A Tabela 26 ilustra os dados de entrada utilizados na equação para as zonas Z1 e Z2.

Tabela 26 – Dados de entrada utilizados para as equações da determinação da largura das zonas Z1 e Z2

ZONA	H _{verga} (m)	L _{janela} (m)	H _{verga} * L _{janela} (m ²)	i _{LZ}
Z1 (DA 50%)	2,4	2,25	5,4	0,1281
Z2 (DA 30%)	2,4	2,25	5,4	0,2265

Aplicando-se a Equação 31, p. 338, chega-se a uma largura de zona medida a partir da aresta da janela de 0,69 m para a Zona Z1 e de 1,22 m para a Zona Z2. Multiplicando-as pelas duas laterais, já que não existe nenhum obstáculo físico que impeça a distribuição da luz, e somando-se a largura real da janela, obtém-se a largura das respectivas zonas. Como resultado, a largura total da Zona Z1 (L_{ZONA}) resultou em 3,63 m e a largura total da Zona Z2 (L_{ZONA}) resultou em 4,17 m. O resultado do zoneamento pode ser visto na Figura 127.

Figura 127 – Representação gráfica da aplicação do zoneamento



3º PASSO: cálculo da DPU baseada na RNA

Para determinar o percentual de horas em que a DPI estaria sendo utilizada (DPU) na Zona Z1, utilizaram-se os valores para os parâmetros de entrada da RNA de acordo com a Tabela 27.

Tabela 27 – Dado de entrada utilizado na RNA para obtenção da DPU

VARIÁVEL	VALOR ADOTADO	VARIÁVEL	VALOR ADOTADO
Refletância Teto (%)	80	DCI_pessoas (W/pessoa)	0,53
Refletância Parede (%)	40	Propriedades Térmicas (pouca troca e absorvância constante, ver Tabela 17) (código)	2
PAF (%)	80		
PAZ (%)	0		
PAZ: abertura única (binário)	0	Largura (m)	2,96
PAZ: abertura distribuída (binário)	0	Profundidade (m)	3,63
Proteção solar horizontal (°)	0	Altura (m)	3
Proteção solar vertical (°)	0	Ocupação (m ² /pessoa)	12
T _{vis}	0,88	Ângulo de obstrução (°)	0
FS	0,819	Influência do piso externo	0
Orientação (°)	90	DPI (W/m ²)	12
DCI_equipamentos (W/m ²)	15	Iluminância-alvo (lux)	500

A RNA 9 (ver Tabela 24, p. 342), escolhida para esse exemplo, retornou DPU de 6,28%h_{DPI}. Para a determinação da DPU da Zona Z2, aplica-se o Fator de Ajuste de DPU para Zona Z2 (FA_{DPU}) igual a 1,6, de acordo com a Figura 126, p. 341, apresentada no item 8.3.2. Multiplicando-se a DPU da Zona Z1 pelo FA_{DPU} para a Zona Z2, obteve-se 10,04%h_{DPI} como DPU para a Zona Z2.

4º PASSO: ponderação da DPU da zona Z1 pela DPI do ambiente

Neste passo, calculam-se a área das zonas Z1 e Z2 e a área remanescente do ambiente em que o aproveitamento da iluminação natural não é computado (DPU = 100%, ou seja, DPI acionada em 100% das horas de ocupação). Para esse exemplo, a área remanescente será chamada de Zona DPI (ZDPI). A obtenção da DPU do ambiente se dá

através da ponderação das DPUs das zonas Z1, Z2 e ZDPI pelas suas respectivas áreas. A Tabela 28 ilustra a síntese da ponderação da DPU para esse exemplo.

Tabela 28 – Resultados da ponderação das DPUs pelas respectivas áreas das zonas

	Área (m ²)	DPU (%h _{DPI})
Área Total do Ambiente	34,58	
Zona Z1	10,74	6,28
Zona Z2	6,01	10,04
Zona DPI	17,83	100
Ponderação:		
DPU ambiente		55,25

8.3.2.3 Verificação do erro da proposta apresentada

Para a verificação dos erros inerentes à aplicação conjunta do metamodelo baseado em redes neurais artificiais com modelos de regressão exponencial, quatro verificações foram feitas:

- verificação do erro inerente às equações de zoneamento dinâmico utilizadas no exemplo;
- comparação do resultado previsto pela RNA para a Zona Z1 com o resultado simulado para a mesma zona;
- comparação do resultado do método simplificado com o resultado simulado para o ambiente todo; e
- comparação do resultado que seria obtido pelo método simplificado se fosse considerada apenas a Zona Z1 com o resultado simulado para o ambiente todo.

A Equação 32 e a Equação 33, utilizadas no exemplo, apresentam as estatísticas exibidas na Tabela 29.

Tabela 29 – Desempenho das equações para 500 lux, PAF 80%, Zona Z1 e Zona Z2

ERROS INERENTES ÀS EQUAÇÕES		
	Equação Z1 500 lux PAF 80% (DA > 50%)	Equação Z1+Z2 500 lux PAF 80% (30% > DA > 50%)
R ²	0,9990	0,9990
SQR	0,6504	0,6651
EAM (m ²)	9,5781	12,0908
EPAM (%)	12,0402	12,2384

No caso do exemplo, o que diferencia o modelo adotado dos modelos utilizados para gerar a equação de regressão é a refletância das superfícies. Os modelos utilizados na regressão apresentavam refletância das superfícies de 20%, 40% e 60% e 30%, 60% e 80% de piso, parede e teto, respectivamente. O ambiente do exemplo se diferenciava do primeiro apenas pela refletância do teto, 80%. A Figura 128 e a Figura 129 mostram em destaque com um círculo tracejado onde os resultados equacionados e simulados das zonas Z 1 e Z 2 estariam plotados nos respectivos gráficos. Observando os dois casos (inseridos no círculo tracejado) mais parecidos com o modelo do exemplo, ambos orientados a Leste e com PAF 80%, pode-se notar que as duas equações maximizam a área da zona para o conjunto de menor refletância média (R 40). Por outro lado, quando comparados com os modelos de refletância alta (R 60), os resultados na equação para Zona Z1 se aproximam aos simulados e os da Zona Z2 subestimam a área da zona. A legenda da nomenclatura dos casos exibidos nas figuras foi apresentada na Figura 117, p. 326.

Figura 128 – Comparação dos resultados da área da Zona Z1 simulados no Daysim e nos Equacionados para PAF 80% 500 lux

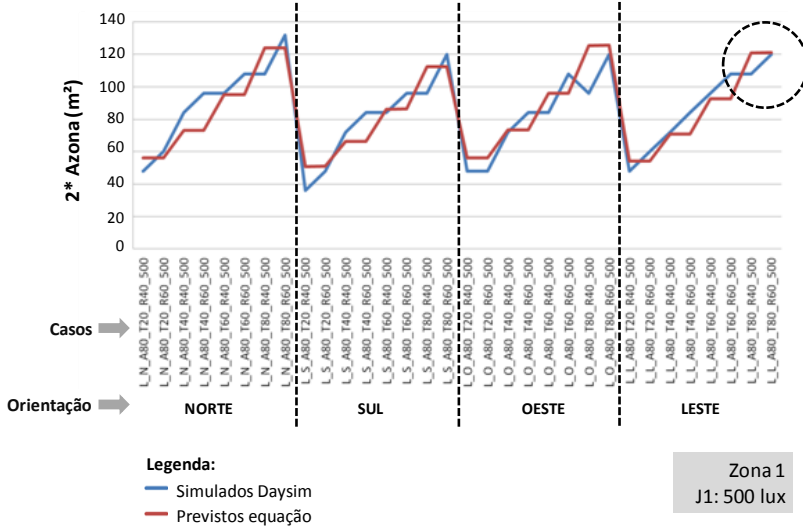



Figura 129 – Comparação dos resultados da área da Zona Z2 simulados no Daysim e nos Equacionados para PAF 80% 500 lux



O resultado da DPU previsto pela rede neural apresentou erro absoluto de 0,5025 DPU ($\%h_{DPI}$) e erro percentual médio de 7,4%, como destacado na Tabela 24, p. 342. É importante salientar que, entre as 10 RNAs treinadas, a RNA 9 apresentou os maiores erros para o conjunto de teste e um erro intermediário para o conjunto de treinamento; entretanto, foi a que apresentou o melhor resultado para o caso desse exemplo. A diferença de desempenho entre as 10 RNAs, tanto para o conjunto de treinamento quanto para o de teste, foi pequena, menos de 1 $\%h_{DPI}$ no caso do erro absoluto (EPAM aproximado de 10%). Já para esse exemplo, considerado um caso “nunca visto”, a diferença de desempenho entre as 10 RNAs chegou a 5 $\%h_{DPI}$ (EPAM aproximado de 70%). Esse tipo de averiguação foi realizado no decorrer deste trabalho e apontou que uma rede com os menores erros no treinamento não necessariamente seria a melhor para generalizar, mesmo nos casos em que não ocorre o superajuste. Esse procedimento possibilitou a escolha de uma RNA com erro considerado aceitável. Os valores de ambas as DPUs, obtidos através da RNA 9 e da simulação computacional para a Zona Z1 no Grasshopper, são apresentados na Tabela 30.

Tabela 30 – DPU para a Zona Z1 prevista pela RNA 9 e simulada pelo plug-in DIVA pelo Grasshopper

J1 500 lux	<i>Cross Validation</i> com Fator de Correção função <i>Logsig</i> – RNA 9 – DPU ($\%h_{DPI}$)	Valor de DPU simulado no <i>plug-in</i> DIVA pelo algoritmo Grasshopper para Zona Z1 – DPU ($\%h_{DPI}$)
	6,28	6,78

Comparando o resultado da aplicação do método simplificado com a simulação do ambiente todo, o erro percentual médio foi inferior a 5%, como pode ser visto na Tabela 31. O obtido para esse ambiente foi considerado aceitável para um método simplificado em que a velocidade na aplicação e o caráter comparativo de soluções são priorizados ante a precisão.

Tabela 31 – Comparação da DPU prevista pelo método simplificado e simulada pelo *plug-in* DIVA, considerando todo o ambiente

DPU do ambiente		
DPU pelo método simplificado	DPU pela Simulação DIVA	Unidade
55,25	57,70	%hDPI
EAM pelo método simplificado	2,45	%hDPI
EPAM pelo método simplificado	4,24	% de erro

Durante o processo de investigação da aplicabilidade do método, primeiramente, o método foi testado utilizando-se apenas a Zona Z1 no cômputo da DPU, quando os erros foram mais elevados, com um erro percentual de 22,87%, de acordo com a Tabela 32. Essa avaliação permitiu validar a necessidade de se trabalhar com as duas zonas de iluminação.

Tabela 32 – DPU do ambiente prevista pelo método simplificado, considerando apenas a Zona Z1

DPU do ambiente considerando apenas Zona Z1		
DPU pelo método simplificado	DPU pela Simulação DIVA	Unidade
70,89	57,70	%hDPI
EAM pelo método simplificado	13,20	%hDPI
EPAM pelo método simplificado	22,87	% de erro

8.4 CONSIDERAÇÕES FINAIS SOBRE O CAPÍTULO

O presente capítulo abordou uma possível aplicação de redes neurais artificiais como método simplificado para a previsão do impacto do aproveitamento da iluminação natural no consumo energético. Como discutido na revisão bibliográfica, é interessante que esse impacto possa ser mensurado não somente no sistema de iluminação, como no de condicionamento de ar. O exemplo de aplicação tratou da previsão da Densidade de Potência em Uso, embora, como visto nos capítulos anteriores, as RNAs apresentem potencial de prever o impacto da iluminação natural também no consumo do sistema de condicionamento de ar. Na proposta apresentada, a DPU foi combinada com um

zoneamento de iluminação natural dinâmico para oferecer a DPU final de um ambiente.

Uma das principais contribuições deste capítulo foi obtida através do zoneamento dinâmico da iluminação natural em comparação às tradicionais “Regras Práticas”. Os resultados mostraram que as regras tradicionais não são suficientemente adequadas para os casos simulados para a cidade de Florianópolis. A consideração de diferentes iluminâncias-alvo para a formulação das equações permite que projetistas utilizem as equações para espaços com diferentes usos e necessidades de iluminamento. A inclusão da Orientação possibilita ao projetista a diferenciação de aberturas em diferentes fachadas. Quanto à precisão, as equações de profundidade e de largura da zona foram consideradas adequadas para um método simplificado. As equações ainda podem ser úteis como apoio ao projeto luminotécnico para a locação de sensores de iluminação natural e a divisão dos circuitos de iluminação artificial.

A principal limitação das equações é a de que a sua formulação baseou-se em modelos computacionais com pé-direito, altura da verga e larguras fixas e sem proteções solares não explorando essas variáveis. Logo, o método não é aplicável a ambientes com variações como pé-direito duplo, por exemplo. Por outro lado, o método abordou limites de PAF, T_{VIS} e refletâncias que abrangem a maior parte dos casos existentes em edifícios reais.

Quanto à proposição da RNA baseada na DPU, ressalta-se que, apesar de esse parâmetro ser relacionado apenas ao sistema de iluminação artificial, ele pode ser utilizado em combinação com outros métodos para gerar informação sobre o impacto no balanço térmico da edificação. Uma aplicação seria utilizar a DPU como dado de entrada para a simulação termoenergética em substituição à DPI como alternativa à simulação integrada. Isso poderia ser feito tanto em simulações detalhadas quanto em simulações simplificadas, com as várias interfaces do programa *EnergyPlus*, por exemplo. Além de dado de entrada para a simulação computacional, pode servir como dado de entrada para outros métodos simplificados destinados à previsão do desempenho térmico da edificação que considerem a influência da densidade de potência instalada de iluminação.

Outra possível aplicação seria para complementar o Regulamento Técnico da Qualidade de Edificações Comerciais, de Serviços e Públicas (RTQ-C) (INMETRO, 2010), aplicando a ponderação de áreas de DPU e DPI para computar o aproveitamento da luz natural junto ao termo

referente à avaliação do sistema de iluminação artificial, da Equação da Pontuação Final do mesmo regulamento (ver Equação 34).

$$PT = 0,30 * \left\{ \left(EqNumEnv * \frac{AC}{AU} \right) + \left(\frac{APT}{AU} * 5 + \frac{ANC}{AU} * EqNumV \right) \right\} + 0,30 * (EqNumDPI) + \quad (34)$$

$$+ 0,40 * \left\{ \left(EqNumAC * \frac{AC}{AU} \right) + \left(\frac{APT}{AU} * 5 + \frac{ANC}{AU} * EqNumV \right) \right\} + b_0^1$$

Assim, utilizando-se a abordagem do exemplo apresentado no item 8.3.2, de considerar a DPU do ambiente em vez da DPI, projetos que priorizem a iluminação natural seriam mais bem valorizados. No procedimento de determinação da eficiência, através da DPU obtida, calcular-se-ia a Potência em Uso, sendo essa utilizada para obter a classificação do nível de eficiência através da comparação com as Densidades de Potência Limite (DPI_L), conforme as Tabelas 4.1 e 4.2 do RTQ-C (INMETRO, 2010). A utilização da DPU deve ser condicionada ao uso de controles de iluminação artificial. A locação desses controles deve ser atrelada ao zoneamento de iluminação natural (Zona Z1 e Zona Z2). Para diferentes tipos de controle, fatores de ajustes poderiam ser propostos, a exemplo do que já acontece na Title 24 (CALIFORNIA ENERGY COMMISSION, 2013) e na ASHRAE 90.1 (ASHRAE, 2013). Ambientes que não dispusessem de sistemas de controle seriam avaliados da forma vigente no regulamento. A ponderação dar-se-ia da mesma forma; entretanto, em vez de considerar somente a Potência Instalada, os ambientes que aproveitam a iluminação natural utilizariam a Potência em Uso. Por fim, a abreviação de Equivalente Numérico de Iluminação – EqNumDPI seria mais adequadamente adaptada para EqNumIL.

Para a determinação da adequabilidade dos níveis de iluminamento atribuídos à iluminação natural, o exemplo de aplicação apresentado poderia ser combinado com abordagens como o diagrama de critérios para a determinação de Autonomia da Luz Natural Espacial (sDA), conforme mostra a Figura 130. Esse diagrama foi proposto no relatório final de Medidas de Iluminação Natural para o *PIER – California Energy Commission* (HESHONG, 2011). O diagrama foi feito com base em equações de regressão, relacionando opiniões de ocupantes e especialistas em iluminação natural sobre o percentual da área de estudo que atingisse ou ultrapassasse o limite de 300 lux por X% de tempo em 75% dos pontos. Para tal, foi utilizada uma escala de

desejabilidade (*Likert scale*), empregada pelos entrevistados para expressar sua satisfação com o ambiente luminoso. O coeficiente de determinação obtido foi baixo, R^2 igual a 0,21, indicando que apenas 21% do conjunto pode ser explicado pela equação. Com isso, salientou-se a necessidade de mais medidas de descrição da qualidade de iluminação natural para aumentar a precisão na descrição do que é um espaço bem iluminado (HESHONG, 2011).

Entretanto, acredita-se que esse tipo de estudo, combinado com classificações de energia, por exemplo, aponta em uma direção mais segura para a classificação de eficiência de um ambiente, pois o ambiente só poderá ser considerado energeticamente eficiente se, em paralelo com a eficiência energética, o conforto dos usuários for atendido através de um ambiente luminoso de qualidade.

Essa avaliação, aplicada ao ambiente do exemplo apresentado no item 8.3.2, complementaria o resultado. Considerando-se 500 lux, poder-se-ia dizer que

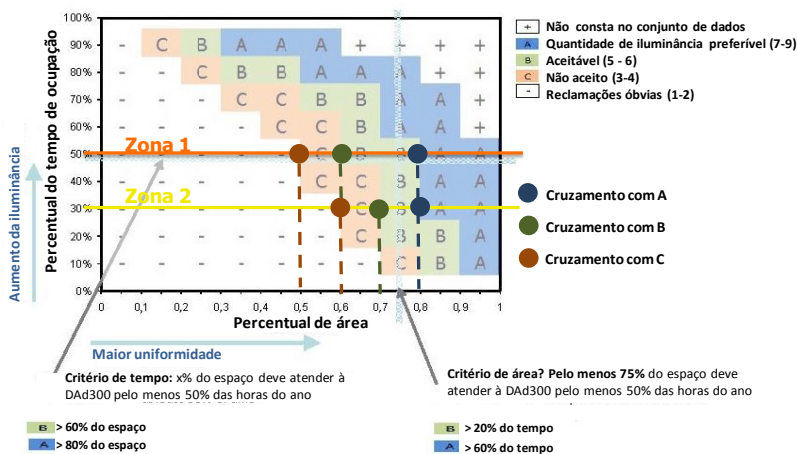
- - 31,1% da área atende 500 lux em 50% do tempo de ocupação (Zona Z1); e
- - 40,4% da área atende a mesma iluminância em 30% do tempo (Zona Z2).
- Aplicando o zoneamento para o mesmo ambiente, mas com iluminância-alvo de 300 lux, poder-se-ia dizer que
- - 67,6% da área atende 300 lux em 50% do tempo de ocupação (Zona Z1); e
- - 100% da área atende a mesma iluminância em 30% do tempo (Zona Z2).

Combinando esses percentuais para 300 lux com o diagrama da Figura 130, que foi proposto considerando essa iluminância-alvo, poder-se-ia acrescentar que o ambiente é suficientemente iluminado, visto que mais de 80% da área do ambiente alcança 300 lux em 30% tempo. Esse resultado foi destacado no diagrama através do cruzamento da linha amarela referente à Zona Z2 com a linha pontilhada azul referente ao percentual de área correspondente para atingir a melhor classificação de desejabilidade do usuário (A).

Como ressalva, deve-se assumir que as classificações para as zonas Z1 e Z2 não são comparáveis entre si, visto que a Z1 é mais rígida que a Z2 em termos de horas e áreas atendidas. Esse diagrama é apropriado para a definição “limites mínimos” com relação à preferência do usuário. Como exemplo, dir-se-ia: caso se atenda o limite da Z1 (DA50%), para que os usuários estejam satisfeitos em grau A, B ou C, a zona deve ocupar um mínimo de X% da área do ambiente.

Figura 130 – Diagrama de critérios para definição de adequabilidade da Autonomia da Luz Natural Espacial

Diagrama resumo dos resultados da pesquisa de Heshong (2011) com base em escalas de adequabilidade (Likert scale) para X% dos sensores em que a iluminância de projeto de 300 lux é alcançada em pelo menos X% das horas do ano.



Fonte: Adaptado de: Heshong (2012).

Além disso, outros aspectos da iluminação natural, como o melhor índice de reprodução de cor (IRC), podem ser relacionados direta ou indiretamente com a eficiência energética. Segundo Papamichael et al. (2015), os IRCs, quando elevados, podem compensar a necessidade de altos níveis de iluminância e, como resultado, reduzir consumo de energia.

A sequência proposta neste capítulo considerou variáveis-chave que foram escolhidas visando à utilização da combinação do metamodelo com o zoneamento, sendo considerada adequada visto que o método mostrou-se com potencial de ser aprofundado. Por outro lado, variáveis de energia como de desempenho do sistema de condicionamento de ar podem ser incluídas – tais como Consumo, Graus hora de Aquecimento e Resfriamento – e, assim, completar o método com um índice similar ao proposto, mas com relação ao impacto no sistema de condicionamento de ar.

Com a evolução de índices de adequabilidade de iluminação natural, ainda se podem incluir mais informações referentes ao ofuscamento, à uniformidade, à direcionalidade e ao espectro da luz, por exemplo. Essas variáveis podem ser medidas ou simuladas e incorporadas à rede neural.

Quanto à simulação da iluminação natural, o ideal seria que as simulações do zoneamento e da DPU tivessem sido feitas com o mesmo número de *bounces*. Isso eliminaria a etapa da proposição do fator de correção e provavelmente reduzir-se-iam os erros. A quantidade de *bounces* adotada para o zoneamento, 5, é mais adequada para a representação do fenômeno, mas, para a aplicação em grande escala, como foi simulado utilizando-se o algoritmo de parametrização do Grasshopper, demandaria elevado esforço computacional. Para esse refinamento, são necessários equipamentos mais potentes ou maior tempo de simulação.

A adoção de regressão exponencial para a proposição das equações dinâmicas de profundidade da zona se mostrou adequada. A fórmula de Lynes baseia-se em DF, e a relação entre DF e DA dos modelos simulados mostrou-se mais bem representada por uma linha de tendência exponencial, o que indicou essa abordagem. Entretanto, como a taxa de variação exponencial é grande, as equações podem retornar um desvio grande no dado de saída para uma variação pequena nos dados de entrada. Uma alternativa ao uso da regressão exponencial seria a proposição de outra rede neural para o zoneamento. Devido ao potencial das redes neurais, é possível que com apenas uma rede se consiga representar o conjunto todo sem precisar fragmentá-lo, como foi feito com as equações. A principal contribuição do zoneamento foi a transposição da fórmula analítica de Lynes para uma abordagem dinâmica da luz natural, permitindo avaliações que consideram as variações das condições de céu.

A formulação analítica para a determinação da largura da zona precisa ser aprofundada considerando maiores variações de proporções de janelas, em especial com diferentes alturas de verga e peitoris mais elevados (janelas altas), além de testada com um maior número de casos. Entretanto, como já foi salientado, como a variação da distribuição da luz natural é menos intensa paralelamente à janela e os casos adotados abordaram proporções diferentes, foi possível chegar a uma relação que considerasse não somente a altura da verga, mas também a proporção do tamanho da janela (fonte de luz).

Com base no que foi observado no Capítulo 7, a rede neural proposta pode ser melhorada através do ajuste adequado do número de neurônios na camada interna e da ampliação do número de casos na amostragem. Dessa forma, pode-se melhorar a sua confiabilidade para a previsão de casos categorizados como “nunca vistos”.

O exemplo de aplicação foi válido para ilustrar o passo a passo do método simplificado e útil para verificar a sua aplicabilidade e delinear

desenvolvimentos futuros. Para refinar o método simplificado para a aplicação em ambientes com mais de uma janela, poder-se-ia propor um índice de sobreposição de zonas. Por fim, o exemplo de aplicação foi feito apenas para a cidade de Florianópolis. Para a utilização desse exemplo em outras localidades, tanto o zoneamento quanto a rede neural devem ser replicados.

9. CONCLUSÃO

Este capítulo apresenta um panorama das principais conclusões deste trabalho. Primeiramente, apresenta-se a conclusão geral e, então, destacam-se as conclusões segundo os capítulos em que foram apresentadas e os objetivos específicos a que se referiam. Por fim, apresentam-se os desdobramentos e as limitações do trabalho e algumas sugestões para trabalhos futuros. No APÊNDICE G p.453 é apresentado um mapa resumo, disponível digitalmente, que relaciona todas as perguntas de pesquisa com as respectivas respostas, o capítulo em que foram abordadas e as etapas metodológicas utilizadas para respondê-las.

9.1 CONCLUSÃO GERAL DO TRABALHO

Inúmeros estudos, como os citados nesta pesquisa, destacam as evidências dos benefícios atribuídos ao aproveitamento da iluminação natural e a importância de se considerar a sua incorporação com base em decisões tomadas nas fases iniciais do projeto. Uma das principais dificuldades da incorporação da iluminação natural em ferramentas simplificadas de estimativa do consumo energético da edificação é sua dupla influência no sistema de iluminação artificial e condicionamento de ar. Os métodos simplificados são as principais ferramentas a serem utilizadas nas etapas iniciais do processo projetual. Se, por um lado, apresentam menor precisão nos resultados, por outro, fornecem respostas rápidas e de certa forma suficientes para o auxílio na tomada de decisões de partido geral. Foram encontrados muitos estudos na literatura indicando elevado potencial do uso de redes neurais artificiais para a regressão multivariada no campo da estimativa do consumo energético e até, em menor escala, considerando, de maneiras específicas, a iluminação natural. Entretanto, lacunas como a possibilidade de modelar o efeito da orientação para zonas térmicas individuais ou aspectos referentes ao contexto e ao desempenho da edificação foram encontradas.

Este trabalho procurou investigar as possibilidades e as limitações da aplicação de redes neurais artificiais para estimar o potencial energético do aproveitamento da iluminação natural em edificações não residenciais através da metamodelagem de suas variáveis-chave.

Os objetivos específicos foram abordados em capítulos individuais de forma a responder a questionamentos elaborados segundo o método sistemático. Para esse fim, adotou-se uma abordagem de investigação-ação buscando testar os limites das redes neurais

relacionados às principais variáveis-chave da iluminação natural. As redes neurais foram utilizadas como metamodelos, tendo seu treinamento realizado com base em resultados obtidos através de simulações computacionais termoenergéticas e/ou integradas. Cada análise baseou-se em simulações de um conjunto de redes neurais a fim de observar tendências de comportamento das redes. Além disso, foram observados os padrões de erros nos conjuntos de treinamento, validação (quando aplicável), teste (abordagem da literatura e conjunto “nunca vistos”).

Os objetivos do trabalho foram cumpridos, visto que se obteve um panorama das possibilidades e das limitações da modelagem da iluminação natural utilizando RNAs diante das principais variáveis-chave que influenciam o fenômeno e as estruturas de RNAs mais difundidas para a representação de funções.

Como possibilidades, as RNAs foram capazes de modelar as variáveis mais significativas e relacionadas aos principais gargalos para a descrição de um ambiente iluminado naturalmente: orientação (operação em diferentes escalas), PAF e T_{VIS} (potencial da fonte de luz: tamanho e transmissividade do material), proteções solares (AVS e AHS: influência na trajetória da luz) e profundidade do ambiente (alcance em relação à fonte). Também possibilitaram a metamodelagem da influência da luz natural para as variáveis de consumo energético de edificações situadas em diferentes localidades, com características climáticas diversas. As RNAs permitiram incluir em uma única rede edificações localizadas nos hemisférios Norte e Sul, evidenciando que podem aprender a diferença resultante do posicionamento geográfico em relação à Linha do Equador (significados opostos) e as variações da trajetória solar conforme localização do edifício. Por fim, apresentaram potencial para modelar variáveis propostas para responder ao conforto humano quanto à suficiência (desejabilidade, por exemplo, sUDI – XXX lux, em XX% do tempo, em XX% do espaço). Nesse caso, a propriedade das redes neurais de aprender mostra-se fundamental, pois esse tipo de variável é muito mais complexo de ser metamodelado, visto que se baseia em parâmetros combinados (por exemplo, iluminância-alvo, tempo e área) e que não descrevem apenas o fenômeno físico. Assim, as redes podem ser apontadas para a modelagem de outras variáveis de conforto que reflitam a satisfação dos ocupantes, em essência mais difíceis de serem modeladas que fenômenos físicos ou modelos matemáticos, pois podem envolver inclusive aspectos sócio-econômicos-culturais.

Quanto às limitações das redes neurais, não foram identificadas limitações conceituais impeditivas da aplicação dessa técnica para os fins deste trabalho. Entretanto, observaram-se alguns pontos que podem restringir o seu uso para determinadas aplicações. A dificuldade para a metamodelagem de variáveis compostas de outras variáveis, tanto de entrada quanto de saída (por exemplo, Abertura Efetiva e sDA), pode ser suprida aumentando-se a quantidade de casos apresentados à rede durante o treinamento; entretanto, esse aumento gera uma demanda por mais simulações computacionais energéticas, podendo inviabilizar a proposição do metamodelo em relação ao tempo. Se a substituição dessas variáveis não for indicada, deve ser feita uma avaliação prévia para verificar a viabilidade e o custo/benefício da proposta. Outro dificultador da aplicação das RNAs é que a interpretação do aumento da quantidade de exemplos de cada variável para melhorar o modelo não é clara (conforme apresentado em 5.3.5.2 e 5.3.6.1), o que dificulta delinear a amostra para treinamento das redes. Por fim, a influência da arquitetura e dos demais parâmetros de treinamento da rede é extremamente relevante; entretanto, em grande parte dos casos a sua definição só pode ser feita por experimentação, o que dificulta a busca por um metamodelo ideal ou de desempenho satisfatório.

O ineditismo da proposta pode ser identificado através das variáveis-chave estudadas e definidas através de lacunas na bibliografia, bem como a abordagem sistemática ante a essa área de estudo, buscando testar, além das possibilidades, as limitações do uso das RNAs. Por fim, o ineditismo também pode ser observado através da proposta do uso de RNAs para modelar a DPU e utilizá-las em conjunto com zoneamento dinâmico da iluminação natural como método simplificado.

Como conclusão geral, pode-se dizer que as RNAs constituem-se uma técnica com potencial para ser aplicada em desenvolvimento de métodos simplificados de iluminação natural sob o enfoque energético. Evidências deste trabalho mostraram que oferecem resultados mais consistentes que as RLMs e que podem modelar o consumo energético para os principais usos finais referentes ao consumo que sofrem influência da iluminação natural, considerando as principais variáveis-chave da descrição do edifício (Orientação, PAF e T_{VIS}) com EPAM inferior a 5%. Quanto ao contexto do edifício, são mais imprecisas, mas, de modo geral, podem modelar diferentes climas e localidades para as referidas variáveis da descrição do edifício com erro inferior a 10%. Quanto aos parâmetros de desempenho do edifício, apresentam maior precisão para estimar valores de consumo energético que de medidas espaciais de iluminação natural. As redes propostas neste trabalho que

consideraram 18 variáveis (11 parâmetros) da descrição do edifício não apresentaram boa capacidade de previsão para Consumo com Iluminação, apresentando EPAM de até 50% para o conjunto “nunca vistos”; e, ao incluir outras localidades no modelo, a imprecisão praticamente dobrou. A solução aqui adotada baseou-se em um conjunto pequeno de 200 amostras de um universo de mais de 10 milhões de combinações. Contudo, baseado em todos os testes conduzidos ao longo do trabalho, acredita-se que, com amostras maiores e ajustes nos parâmetros das redes, as RNAs podem ser aplicadas satisfatoriamente (com erros inferiores a 10%) para avaliações energéticas da iluminação natural.

Quanto à aplicabilidade do método simplificado proposto, destacam-se a precisão alcançada e o tempo de retorno. Com relação à precisão, obtiveram-se erros inferiores a 5% quando comparado à simulação computacional; e, com relação ao tempo de retorno, uma rede devidamente calibrada oferece respostas imediatas, ao passo que as simulações integradas realizadas neste trabalho para uma zona termoluminosa demoraram em média 3,6 minutos (12,17 h, em média, para simular 200 casos, como mostrado no item 7.3.3).

Como principal contribuição social e prática do trabalho, destaca-se um método passível de ser aplicado em todo o território nacional para auxiliar projetistas e contribuir para códigos e normas locais. Como contribuição científica e teórica, destaca-se o avanço nos estudos de aplicação de inteligência artificial para a modelagem dos fenômenos físicos dinâmicos envolvidos no desempenho luminoso e térmico dos edifícios.

9.2 CONCLUSÃO SOBRE AS VARIÁVEIS-CHAVE PARA A ILUMINAÇÃO NATURAL RELACIONADOS AO CONSUMO ENERGÉTICO DA EDIFICAÇÃO (1.º OBJETIVO ESPECÍFICO)

Ao longo dos Capítulos 4 a 7, as RNAs foram testadas ante as variáveis-chave da edificação influentes na iluminação natural/consumo energético. No total foram avaliadas 22 variáveis da descrição, 14 do contexto e 17 do desempenho do edifício. As variáveis Orientação, PAF e T_{VIS} foram consideradas essenciais nos testes.

As redes foram capazes de modelar os efeitos de Orientação, PAF, T_{VIS} , FS, AVS, AHS, Profundidade e Geometrias diferentes no Consumo Energético Total, apresentando erros inferiores a 5%, como foi observado no Capítulo 4. Destaca-se que o Consumo Energético Total foi a variável de saída mais facilmente prevista pelas redes, visto

que as variações de aquecimento, resfriamento e iluminação têm seus efeitos mitigados nesta variável, facilitando o aprendizado da RNA.

Os efeitos das variáveis Orientação, PAF e T_{VIS} no consumo separado por usos finais puderam ser previstos pelas redes com erros próximos a 5% (ora superiores, limitados a 10%; ora inferiores; ver Figura 27, p. 164, e Figura 60, p. 208). Os resultados referentes ao Aquecimento desta tese não foram considerados, pois a pouca necessidade de aquecimento nos climas brasileiros e, conseqüentemente, os baixos valores absolutos da variável geraram resultados ruidosos.

O agrupamento de PAF e T_{VIS} em Abertura Efetiva foi considerado um complicador para as redes. Concluiu-se que, ao agrupar variáveis, mais exemplos devem ser disponibilizados durante o treinamento, pois a rede deve aprender o resultado da combinação dessas variáveis em um único índice, além da sua combinação com as demais variáveis resultar em menos neurônios de entrada.

Devido à grande quantidade de variáveis da descrição do edifício incluídas nas redes no Capítulo 7, não foi possível observar o efeito de cada uma delas independentemente. Optou-se por tentar agrupar em um metamodelo todas as variáveis consideradas influentes no fenômeno, mas o tamanho das amostras utilizadas nos treinamentos foi considerado insuficiente para que a rede pudesse aprender o fenômeno e generalizar, como foi observado nos resultados dos conjuntos “nunca vistos” (ver Figura 109, p. 305, e Figura 110, p. 306). Entretanto, concluiu-se que os demais resultados apresentados nos Capítulos 4 e 5 indicam que o metamodelo pode aprender os efeitos dessas variáveis baseado em um conjunto de treinamento mais robusto e ajustes nas configurações das redes.

Quanto às variáveis do contexto do edifício, concluiu-se que, para um melhor desempenho dos metamodelos, devem ser apresentadas variáveis de localização geográfica, características térmicas e disponibilidade de luz durante a fase de treinamento. As variáveis GDR e GDA descreveram melhor os efeitos do fenômeno térmico para as redes que as variáveis TBS, UR e ΔT (ver Figura 77, p. 241, e Figura 78, p. 242). Quanto ao aspecto luminoso associado ao clima, a RSG_a e a Nb_a foram mais efetivas na descrição do fenômeno para o aprendizado das redes do que a variável IGH_a para os testes realizados neste trabalho (ver Figura 79, p. 244, e Figura 80, p. 244).

Por fim, quanto às variáveis de desempenho, as variáveis referentes ao consumo energético foram consideradas mais fáceis de serem aprendidas pelas redes. Esse resultado levanta duas hipóteses: a primeira é de que o fenômeno luminoso é mais difícil de ser modelado;

e a segunda é de que as variáveis escolhidas para descrever o desempenho luminoso são mais difíceis de serem modeladas. Nesse caso, outras variáveis que também pudessem dar informações sobre o comportamento luminoso dos ambientes poderiam ser mais facilmente aprendidas.

Sobre a primeira hipótese, o fenômeno luminoso é mais sensível à geometria dos ambientes e dos entornos imediatos, bem como à forma das proteções solares do que o térmico. Enquanto o fenômeno térmico pode ser modelado no nível da edificação, o luminoso deve ser modelado no nível do ambiente, em que o efeito dessas variáveis pode ser avaliado. Mesmo quando ambos são avaliados no nível do ambiente, os parâmetros termoenergéticos são mais facilmente avaliados.

A variável Consumo para Iluminação é decorrente do desempenho da iluminação natural, mas não é tão sensível a tais alterações quanto o $DA_{\text{médio}}$, sendo em teoria conceitos complementares. Isso porque o Consumo para Iluminação é decorrente da posição de sensores para dimerização, devendo a sua localização, desde que bem distribuída, gerar uma informação geral do ambiente. Já o $DA_{\text{médio}}$, por exemplo, é mais sensível a valores extremos medidos na malha de pontos (ver Figura 31, p. 171).

Sobre a segunda hipótese, acredita-se o DA_{mediano} seja mais representativo do que o $DA_{\text{médio}}$ para as redes. As variáveis sDA, sUDI e sFLD, por exemplo, são mais complexas, pois agregam mais uma informação, a espacialidade (ver Figura 104, p. 297, e Figura 105, p. 299). A estimativa de um DA pontual, por exemplo, deve ser mais facilmente modelada pelas redes. A exemplo do que foi observado para Abertura Efetiva, variáveis combinadas, tanto de entrada da rede como de saída, exigem mais exemplos de treinamento e redes mais robustas.

As três medidas dinâmicas espaciais combinam informações de quantidade de luz admitida, conforme a variação no tempo e a sua distribuição no espaço. Os conjuntos de treinamento utilizados apresentavam três Padrões de Ocupação diferentes, o que torna as redes mais complexas para a estimativa de medidas dinâmicas. Assim, redes individuais para diferentes ocupações devem simplificar a modelagem dessas variáveis. Quanto à questão espacial, o conjunto amostrado para o treinamento considerou as variáveis de entrada largura, profundidade e altura do pé-direito agrupadas no parâmetro Geometria, através de proporção e tamanho de ambientes fixos. Entretanto ao propor as RNAs estas variáveis foram desagrupadas, aumentando a possibilidade de ocorrência de combinações desconhecidas para a RNA. Concluiu-se que

esta abordagem gerou uma amostra insuficiente para o aprendizado das redes.

Nesse caso, a utilização dos mesmos códigos utilizados na amostragem para Geometria para a RNA e um aumento do tamanho da amostra podem melhorar o desempenho da rede, mas torna o modelo menos generalista em termos das formas dos ambientes. A substituição da codificação da geometria por informações de largura, profundidade e altura do pé-direito, de forma a desagregar as informações presentes nas variáveis-chave de entrada da rede, apesar de aumentar a quantidade de combinações paramétricas, deve simplificar a estrutura das redes e tornar a influência dessas variáveis no fenômeno mais fácil de ser modelada.

Tabela 33 – Compilação das variáveis-chave testadas nas RNAs ao longo do trabalho

	variáveis -chave		
	descrição do edifício	contexto do edifício	desempenho do edifício
Capítulo 4	Orientação, PAF, FS, AVS, AHS, PROF e Geometria (proporção)		Consumo Energético Total
Capítulo 5	Orientação, PAF, T _{VIS} , Ventiladores, Abertura Efetiva (PAF*T _{VIS}) e FS		Consumo Energético Total, Consumo para Aquecimento, Resfriamento e Iluminação/ Iluminância Média e Autonomia da Luz Natural Média
Capítulo 6	Orientação, PAF e T _{VIS}	a localização geográfica: Latitude, Longitude e Altitude; as características térmicas: Graus Dia de Resfriamento (GDR) e Graus Dia de Aquecimento (GDA); a disponibilidade de luz: Radiação Solar Global Acumulada (RSGa) e a Nebulosidade Acumulada (Nba)/ Temperatura de Bulbo Seco (verão) – média (TBS _v), Temperatura de Bulbo Seco (inverno) – média (TBS _i), Umidade Relativa (verão) – média (UR _v), Umidade Relativa (inverno) – média (UR _i), Variação de Temperatura (verão) – média (ΔT_v) e Variação de Temperatura (inverno) – média (ΔT_i)/Iluminância Global Horizontal Acumulada.	Consumo Energético Total, Consumo para Aquecimento, Resfriamento e Iluminação
Capítulo 7	Orientação, Abertura (PAF e PAZ), Vidros (T _{VIS} e FS), Proteção solar (AVS e AHS), Propriedades Luminosas das Superfícies (Refletâncias), Propriedades Térmicas (Absortância e Transmitância), Geometria (Proporção e Tamanho), Ângulo de Obstrução do Entorno, Iluminância de Projeto (alvo), DPI, DCI (Equipamentos e Pessoas) e Padrão de Ocupação.	a localização geográfica: Latitude, Longitude e Altitude; as características térmicas: Graus Dia de Resfriamento (GDR) e Graus Dia de Aquecimento (GDA); a disponibilidade de luz: Radiação Solar Global Acumulada (RSGa) e a Nebulosidade Acumulada (Nba)	Autonomia da Luz Natural Espacial para 50% e 30% das horas do ano; três faixas de Iluminâncias Úteis para esses mesmos percentuais de horas de atendimento; Fator de Luz Diurna Espacial para duas frequências de ocorrência / Consumo Energético Total, Consumo para Aquecimento, Resfriamento, Iluminação, e Densidade de Potência de Iluminação em Uso.
Total de variáveis diferentes	22	14	17

Fonte: Autor.

9.3 CONCLUSÃO SOBRE O POTENCIAL DAS REDES NEURAIS ARTIFICIAIS DIANTE DA REGRESSÃO LINEAR MULTIVARIADA (2.º OBJETIVO ESPECÍFICO)

Para a verificação da aplicabilidade do uso de RNAs para a modelagem do consumo energético visando à iluminação natural, comparou-se a aplicação de redes *perceptron* multicamadas utilizando a retropropagação do erro com regressão linear multivariada. Na comparação entre os modelos, as redes neurais apresentaram desempenho superior com R^2 de 0,98, enquanto o mesmo conjunto para a regressão linear apresentou R^2 de 0,62. O desvio padrão foi de 0,16 e 2,90, respectivamente, indicando menor dispersão dos dados para o modelo utilizando redes neurais. Além disso, as equações propostas usando regressão linear excluía o parâmetro orientação, que foi possível ser modelado através das redes neurais.

Para testar as RNAs com casos realmente nunca vistos pelas redes, novas orientações, AVS e geometrias foram utilizadas. Três das 10 RNAs propostas foram selecionadas para os testes. Na avaliação individual, os maiores erros ocorreram para a orientação 359° N, indicando a necessidade de informação sobre condição de escala polar. Na sequência, os maiores erros ocorreram para diferentes geometrias e, então, para AVS. A principal justificativa para os erros de AVS foi a adoção de valores binários que indicavam ou não a existência de proteção solar para a rede; portanto, uma questão conceitual de estruturação da rede e não uma limitação do modelo. Quanto à avaliação das novas proporções das geometrias, concluiu-se que a geometria profunda apresentou erro maior por sofrer maior influência do gradiente de distribuição de luz, também influenciado pelas refletâncias superficiais (variação da iluminação natural para o fundo do ambiente), tornando a modelagem do fenômeno mais complexa.

Os parâmetros de entrada Profundidade e PAF foram considerados insuficientes para gerar informações sobre os modelos, indicando-se a complementação desses com outros parâmetros, tais como Percentual de Abertura por Área de Piso (PAP), que indiquem proporção do ambiente. Por fim, essa etapa do estudo permitiu observar a importância de não se avaliarem RNAs baseadas em estudos paramétricos somente pelo conjunto de teste (selecionado considerando um percentual do conjunto total), mas também pelo conjunto “nunca vistos”. O percentual de erro entre esses dois conjuntos variou de EPAM 0,77% a EPAM 5%, respectivamente. Além disso, os resultados mostraram que optar pela rede que gerou menores erros para o conjunto

de treinamento, teste ou mesmo para todos os conjuntos de maneira global não necessariamente levará à escolha da rede com melhor desempenho na predição dos casos nunca vistos. Esse fato salientou a importância da observação dos conjuntos em separado, atentando para o potencial de convergência e generalização das redes.

9.4 CONCLUSÃO SOBRE AS VARIÁVEIS DA DESCRIÇÃO DO EDIFÍCIO (3.º OBJETIVO ESPECÍFICO)

A lacuna encontrada na revisão bibliográfica que originou este capítulo foi a necessidade de verificar, em caso positivo, de que forma as redes neurais poderiam modelar o efeito da orientação em ambientes com aberturas em uma só fachada, considerando apenas uma zona térmica. Essa configuração tende a majorar o impacto da iluminação e seus efeitos dinâmicos no consumo energético total da edificação, dificultando a sua modelagem. Logo, a principal contribuição foi propor um modelo que pudesse ser utilizado no nível do ambiente, que é a escala do edifício em que a luz natural pode ser mais bem analisada.

Essa observação inicial levou ao questionamento do desempenho de RNAs para modelar variáveis que operam em diferentes escalas. A condução dessa investigação, motivada pelas demais perguntas originadas, levou a conclusões que partiram da seleção das variáveis-chave Orientação, PAF e T_{VIS} como variáveis críticas para a iluminação natural sob o enfoque do consumo energético.

A variável Orientação confirmou-se como a de modelagem mais complexa. As variáveis apresentaram diferentes desempenhos para diferentes quantidades de exemplos. As curvas de redução de desempenho, apresentadas na Figura 63, p. 212, caracterizam-se por um início com variação mais acentuada e por um fim tendendo à linearidade, mostrando que o aumento de quantidade de casos não necessariamente irá melhorar o desempenho da rede. Logo, a partir de determinado ponto, acrescentar casos ao treinamento irá aumentar o esforço computacional, ao passo que não irá melhorar significativamente o seu desempenho. A variável PAF foi a que apresentou a curva mais acentuada com tendência linear no final, indicando que a variável precisa de menos exemplos no treinamento.

Não foi possível comprovar benefício no agrupamento de T_{VIS} e PAF no parâmetro Abertura Efetiva. O desempenho das redes aparentemente piorou; entretanto, como não foram simulados novos casos, o agrupamento das variáveis gerou menos casos para serem apresentados à rede na fase de treinamento. Entendeu-se que o

agrupamento de parâmetros torna o aprendizado da rede mais complexo, visto que os seus efeitos são combinados. Logo, supõe-se que o agrupamento de parâmetros requer maior número de casos para o treinamento a fim de permitir que a rede possa aprender um conjunto maior de combinações e, assim, possa generalizar respostas para novos casos.

Quanto aos parâmetros de desempenho avaliados preliminarmente no Capítulo 5, os parâmetros de desempenho energético (consumo total, aquecimento, resfriamento e iluminação) apresentaram erros inferiores aos de iluminação natural (Iluminância média e DA médio). Notou-se também que a definição dos parâmetros de saída influencia o ajuste de pesos da rede, alterando os resultados. Essa conclusão pode ser observada em especial para o parâmetro Resfriamento, quando da inclusão do parâmetro Ventiladores.

Por fim, a arquitetura da rede mostrou-se de fundamental importância, em especial quanto ao número de neurônios na camada oculta. A ferramenta do EasyNN-plus para a definição do número de neurônios ocultos, bem como as heurísticas adotadas oferecem uma ideia inicial do número de neurônios, mas não garantem uma boa configuração de rede, sendo sempre necessários novos testes experimentais. A variação do número de neurônios foi responsável pela redução do EPAM a menos da metade para todos os parâmetros de saída. Outro parâmetro considerado importante foi a escolha do algoritmo de treinamento, em especial pela possibilidade da redução do tempo de simulação das RNAs.

Quanto à avaliação do potencial das redes, os erros do conjunto de treinamento (convergência), em geral, foram inversamente proporcionais aos erros dos conjuntos “nunca vistos” (generalização). Tal resultado afirma a contribuição do método de avaliação proposto neste trabalho, mais detalhado e rigoroso do que sugere a bibliografia, pois, ao avaliar individualmente cada conjunto das etapas do treinamento e o conjunto “nunca vistos”, possibilitou a identificação das limitações dos modelos.

9.5 CONCLUSÃO SOBRE AS VARIÁVEIS DO CONTEXTO DO EDIFÍCIO (4.º OBJETIVO ESPECÍFICO)

Quanto às variáveis do contexto do edifício, a principal contribuição deste trabalho foi explorar as possibilidades de modelagem de características da localização e do clima em que o edifício está

inserido com poucas variáveis-chave. A revisão bibliográfica indicou espaço para pesquisas considerando as variações anuais do clima e de indicações da localização geográfica, com agrupamento de diferentes localidades em uma mesma RNA.

Para responder às perguntas geradas, foram selecionadas variáveis-chave de fácil obtenção, considerando a localização geográfica, características térmicas do clima e disponibilidade de luz. A influência da arquitetura da rede e dos agrupamentos de variáveis dessas três categorias foi avaliada, seguida da avaliação do agrupamento de localidades de diferentes hemisférios na mesma rede. O critério para definir os limites para cada variável-chave também foi avaliado, visto que, para um mesmo clima, as variáveis são dependentes umas das outras. Diferentes variáveis para a mesma categoria também foram avaliadas e, por fim, o método de teste dos metamodelos foi discutido.

Concluiu-se que o parâmetro determinante para a arquitetura da rede foi o balanço entre desempenho da rede e tempo de treinamento, visto que as redes tornaram-se mais complexas, demandando maior esforço computacional. A Regularização Bayesiana foi a que apresentou melhores condições, em especial pelo tempo de simulação. O número de neurônios foi escolhido pelo balanço entre os erros do conjunto de treinamento e o conjunto “nunca vistos”, em especial pelos erros do segundo, visto que foram significativamente maiores.

Quanto aos agrupamentos das três categorias (localização geográfica, características térmicas do clima e disponibilidade de luz), a melhor solução contemplou as três categorias juntas; entretanto, os parâmetros de localização geográfica mostram-se os mais expressivos. Os diferentes agrupamentos resultaram em diferentes padrões de erros tanto entre os conjuntos de treinamento e “nunca vistos” quanto para cada um dos parâmetros de saída da rede (variáveis de desempenho).

A avaliação sobre o agrupamento de cidades de diferentes Hemisférios mostrou que a inclusão das cidades do Hemisfério Norte no modelo dificultou o treinamento da rede (convergência), apresentando erros um pouco maiores (a maior diferença foi em torno de 1%, no caso da saída Resfriamento). Por outro lado, melhorou o poder de generalização da rede (“nunca vistos”) em quase 10%. Como os maiores erros são sempre para o conjunto “nunca vistos”, a melhora nos resultados desse conjunto aumenta significativamente o desempenho da rede de maneira geral.

A escolha dos limites das variáveis-chave para a definição do conjunto de treinamento baseando-se na Latitude mostrou-se insuficiente. Como todas as variáveis-chave adotadas neste estudo são

vinculadas ao arquivo climático da cidade e dependentes entre si, nem sempre é possível que todas as variáveis estejam distantes dos valores extremos para evitar a extrapolação. O ajuste dos limites dos valores das variáveis-chave das cidades do conjunto de treinamento deve considerar cidades com valores-limite de forma geral. A cidade de Salvador apresentou essa característica e, ao ser substituída pela cidade do Rio de Janeiro (mesma zona bioclimática), o desempenho da rede melhorou. Logo, ao selecionar uma cidade representativa de uma zona bioclimática, deve-se escolher uma cidade com características climáticas extremas para o maior número de variáveis possível.

Quanto à substituição dos parâmetros térmicos, os derivados GDR e GDA mostraram-se mais adequados para a descrição do comportamento térmico que os parâmetros primários TBS, UR e ΔT . Vale ressaltar que este trabalho estudou apenas ambientes condicionados. A inclusão de informações sobre a Iluminância Horizontal Global Acumulada nas RNAs não foi conclusiva quanto à melhora do desempenho das redes, visto que apresentou resultados conflitantes para diferentes algoritmos de treinamento. Logo, pode-se concluir que existe a possibilidade de melhora da rede, mas esse não é um parâmetro determinante para o desempenho da rede.

Por fim, a comparação entre os métodos de teste das redes neurais foi necessária para salientar a importância de se testarem as redes com o conjunto “nunca vistos”, no caso de estudos paramétricos. Como já frisado ao longo do trabalho, existem muitas aplicações de redes neurais nas áreas da biologia, da exploração de petróleo ou mesmo de energia, nas quais separar o conjunto de dados em percentuais para treinamento e teste faz sentido, pois se trata de observações reais. Entretanto, em estudos paramétricos em que se pretende criar um modelo que represente um cenário baseado em uma amostra de casos possíveis, o conjunto “nunca vistos” é fundamental para uma abordagem segura das limitações do modelo. No caso estudado neste capítulo, a abordagem do conjunto “nunca vistos” apresentou o dobro de erro médio percentual comparado à solução recorrente na bibliografia (percentual do conjunto para teste).

9.6 CONCLUSÃO SOBRE AS VARIÁVEIS DO DESEMPENHO DO EDIFÍCIO (5.º OBJETIVO ESPECÍFICO)

Duas categorias de variáveis do desempenho do edifício foram abordadas: variáveis referentes ao consumo energético e ao conforto humano sob a ótica da suficiência da quantidade de luz (iluminância). A

principal contribuição deste capítulo foi salientar as relações entre as variáveis de desempenho de diferentes categorias e destacar os efeitos de seu agrupamento e potencial de predição. Um grupo maior de variáveis-chave foi adotado utilizando-se a técnica de Amostragem Hiper-cubo Latino (ALH). A simulação integrada foi adotada a fim de melhor avaliar a influência dessas novas variáveis. O acréscimo dessas variáveis aumentou a complexidade das redes, piorando o seu desempenho.

Quanto à operacionalização dos testes de desempenho, testaram-se três tamanhos de amostragens. A amostra de 200 casos foi escolhida por apresentar padrão de erro e tempo de processamento intermediários. Os três conjuntos amostrados apresentaram maiores dificuldades na previsão dos parâmetros de desempenho de iluminação natural, tendo cada parâmetro de saída de iluminação natural apresentado, em média, EPAM da ordem de 3%, enquanto que a soma dos quatro parâmetros de energia (descontando o aquecimento) não ultrapassou 0,5%. Nessa etapa toda a amostra foi utilizada para treino e teste para evitar observações tendenciosas. Essa opção resultou em erros elevados para o conjunto “nunca vistos” nas etapas seguintes.

Quanto às variáveis adotadas no conjunto “nunca vistos”, as variáveis da descrição do edifício foram as mais difíceis de serem previstas, apresentando maiores erros, seguidas das variáveis do contexto e, por fim, das iluminâncias-alvo, também agrupada nas variáveis da descrição do edifício, mas referente a interações com outros sistemas da edificação. Apesar de o método AHL ter apresentado bom desempenho na distribuição das amostras, acredita-se que os conjuntos de amostras devem ser maiores a fim de que a rede neural possa aprender de maneira mais eficiente, em especial, os efeitos do fenômeno da iluminação natural. Para a consideração de mais climas, acredita-se que a amostragem de cidades considerando o território nacional poderá melhorar o desempenho das redes, levando-se em consideração os limites das variáveis, como indicado no Capítulo 6. Os parâmetros de energia foram menos sensíveis à inserção das variáveis do contexto do edifício, apresentando menor piora na predição quando adicionadas as outras duas cidades ao modelo.

A inclusão de novas variáveis de entrada e de saída da rede neural aumentou significativamente o esforço computacional necessário para o treinamento das redes. Entretanto, o agrupamento das variáveis de diferentes naturezas se mostrou benéfico para o ajuste dos pesos e para os resultados finais, especialmente para os parâmetros de iluminação natural. Os parâmetros de energia mostraram-se mais independentes,

mas, no caso da generalização (conjunto “nunca vistos”), também se beneficiaram do agrupamento de variáveis de diferentes naturezas. A variável DPU, por sua vez, obteve menores erros quando apresentada independentemente das RNAs.

Por fim, o algoritmo desenvolvido para a simulação paramétrica integrada nos *plug-ins* DIVA/Grasshopper do Rhinoceros, com leitura dos arquivos gerados pela Amostragem Hipercubo Latino do MATLAB, permitiu a simulação de novas amostragens do mesmo conjunto de variáveis, facilitando a realização dos testes propostos especialmente com relação à agilidade e evitando erros humanos durante o processo.

9.7 CONCLUSÃO SOBRE A PROPOSIÇÃO DO MÉTODO SIMPLIFICADO

A proposta apresentada no Capítulo 8 abordou um método simplificado para a determinação da DPU no nível do ambiente. Ao longo do trabalho, destacou-se a possibilidade de utilização de redes para a previsão da influência do aproveitamento da iluminação natural no consumo do sistema de condicionamento de ar, aqui abordado para uma zona térmica. Entretanto, optou-se pela apresentação de um exemplo de aplicação considerando apenas a DPU com a intenção de explorar esse parâmetro diante dos métodos simplificados difundidos como “regras práticas” ou similares, adotados por códigos e normas. O método permitiu a avaliação do potencial do aproveitamento da iluminação natural segundo zonas de iluminação natural, considerando as variações dinâmicas do clima. Além disso, testes realizados apontaram para a possibilidade de avaliação de ambientes com janelas em diferentes superfícies. Os maiores erros foram atribuídos aos da própria rede neural adotada, que pode ser mais bem trabalhada, visto que a proposta deste trabalho foi explorar potencialidades e limitações das RNAs e não propor uma rede de alto desempenho. O erro da aplicação do método foi menor que 5%. O aprofundamento dessa proposta pode gerar um método passível de ser aplicado em diversas localidades e de auxiliar arquitetos e engenheiros a elaborarem projetos que considerem a iluminação natural.

9.8 DESDOBRAMENTOS DO TRABALHO

O algoritmo proposto para a simulação integrada paramétrica foi concebido visando permitir simulações de novas amostras, bem como gerar algoritmos genéticos (algoritmo de otimização). Essa implementação futura deve permitir a classificação de ambientes

oriundos de combinações de variáveis-chave que gerem espaços mais ou menos eficientes quando avaliados pelos parâmetros de desempenho passíveis de serem previstos pelo algoritmo. No caso de continuidade deste estudo, tratar-se-ia de variáveis de suficiência de iluminação natural e consumo energético.

9.9 LIMITAÇÕES DO TRABALHO

Este trabalho abordou uma grande quantidade de arquiteturas de redes neurais; entretanto, existem inúmeras outras possibilidades de soluções que podem levar a desempenhos diferentes. Estudaram-se apenas configurações de RNAs recorrentes (sem realimentação das saídas para as entradas) e com aprendizagem supervisionada.

As principais limitações do estudo são:

- as variáveis térmicas da edificação foram abordadas de maneira superficial, visto que o foco principal do trabalho foi o estudo dos efeitos da iluminação natural no consumo energético;
- foram considerados apenas ambientes condicionados com condicionamento de ar tipo *split* e com carga ideal;
- as variáveis do contexto do edifício basearam-se em dados de arquivo climático de cada cidade, não sendo combinadas entre si (por exemplo, latitude e longitude referentes a cada cidade, não houve combinações entre diferentes latitudes e longitudes);
- o entorno, bem como os elementos de proteção solar foram considerados de forma simplificada com apenas uma refletância e verificados através de ângulo de obstrução/sombreamento considerando diferentes orientações;
- não foram considerados vidros com propriedades dinâmicas;
- não foram consideradas proteções solares móveis externa ou internas;
- o sistema de controle de iluminação artificial com acionamento baseado na iluminação natural limitou-se ao processo de dimerização ideal;
- as equações de zoneamento abrangem somente a iluminação lateral e também consideram a obstrução de forma simplificada (Fator de Obstrução). A ausência de

brises deu-se a fim de manter a estrutura da fórmula empírica, que serviu como base para o estudo e que deriva do Fator de Luz Diurna. A profundidade das zonas limita-se à profundidade dos modelos utilizados para gerá-las, no caso 8 m;

- as equações do zoneamento são exponenciais, logo pequenas variações nos parâmetros de entrada podem gerar grande influência nos resultados das equações, dependendo da curva exponencial; e
- as intervenções dos usuários não foram consideradas.

9.10 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Com base na investigação conduzida neste trabalho e em seus resultados, sugerem-se como trabalhos futuros os seguintes tópicos:

- investigar redes neurais que trabalham com dados contínuos;
- testar a implementação de outros tipos de proteção solar (por exemplo, telas perfuradas ou cobogós); parâmetros dinâmicos das aberturas (por exemplo, vidros dinâmicos, *brises* móveis) e outros tipos de controle de iluminação artificial. O DIVA permite a análise da influência de cortinas e persianas, além da interferência do usuário através do algoritmo *Lightswitch*. Esses parâmetros não foram abordados devido ao incremento na quantidade de variações no conjunto e na complexidade dessas interferências;
- testar novos índices para a descrição das variáveis-chave, como para proteções solares, visto que o ângulo de sombreamento apresenta limitações, ou para a substituição ou inclusão de variáveis, como percentual de abertura por área do piso;
- testar mais geometrias e aumentar o conjunto “nunca vistos” de forma geral;
- testar o potencial de redes neurais diante de demais parâmetros da iluminação natural, em especial os de conforto do usuário, tais como ofuscamento, direcionalidade e contrastes de iluminâncias;
- propor redes neurais baseadas em novas amostragens e aprofundá-las nas arquiteturas de rede, visando à redução de erros;

- testar novas amostragens com mais localidades e outros parâmetros de entrada do contexto da edificação;
- desenvolver do método simplificado DPU, aprofundando a RNA proposta e testando mais soluções de zoneamento;
- incluir influência da iluminação natural no condicionamento de ar no método simplificado Zoneamento Dinâmico – DPU;
- propor zoneamento dinâmico para aberturas Zenitais;
- testar zoneamento baseado em redes neurais, em vez da regressão não linear exponencial;
- definir índices de sobreposição de zonas para ambientes com janelas em superfícies opostas ou adjacentes.

REFERÊNCIAS

- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. NBR 5413 Versão Corrigida:1992. Iluminância de Interiores. **Associação Brasileira De Normas Técnicas**. 5413.Rio de Janeiro. N. 13.1992.
- _____. ABNT NBR 15215-3: 2005 Versão Corrigida:2007. Iluminação natural - Parte 3: Procedimento de cálculo para a determinação da iluminação natural em ambientes internos. **Associação Brasileira De Normas Técnicas**. Rio de Janeiro. N. 36. 2005a.
- _____. ABNT NBR 15220-3: 2005 Desempenho térmico de edificações. Parte 3: Zoneamento bioclimático brasileiro e diretrizes construtivas para habitações unifamiliares de interesse social. **Associação Brasileira De Normas Técnicas**. Rio de Janeiro. 2005b.
- _____. ABNT NBR 15215-3: 2005 Versão Corrigida: 2007. Iluminação natural - Parte 3: Procedimento de cálculo para a determinação da iluminação natural em ambientes internos. **Associação Brasileira De Normas Técnicas**. ABNT NBR 15215-3: 2005 N. 36.2007.
- _____. NBR ISO/CIE 8995-1: 2013 Iluminação de ambientes de trabalho- Parte 1: Interior. **Associação Brasileira De Normas Técnicas**. Rio de Janeiro. N. 46.2013.
- ABU BAKAR, N. N.; *et al.* Energy efficiency index as an indicator for measuring building energy performance: A review. **Renewable and Sustainable Energy Reviews**, v. 44, p. 1-11. 2015.
- AGHEMO, C.; PELLEGRINO, A. LOVERSO, V. R. M. The approach to daylighting by scale models and sun and sky simulators: A case study for different shading systems. **Building and Environment**, v. 43, n. 5, p. 917-927. 2008.
- AHMAD, A. S.; *et al.* A review on applications of ANN and SVM for building electrical energy consumption forecasting. **Renewable and Sustainable Energy Reviews**, v. 33, p. 102-109. 2014.
- AHMED, A.; *et al.* Assessing the performance of naturally day-lit buildings using data mining. **Advanced Engineering Informatics**, v. 25, n. 2, p. 364-379. 2011.
- ALMADA-LOBO, B. **Métodos Estatísticos de Previsão – Análise de Erros**. Departamento de Engenharia Mecânica e Gestão Industrial, Faculdade de Engenharia, Universidade do Porto. Porto. 2007. Disponível em: <http://sigarra.up.pt/feup/pt/conteudos_service.conteudos_contptc_id=34385&pv_cod=08tafWzUhnra>. Acesso em: junho de 2012.
- ALMEIDA, A. M.; MARTINS, A. G. Efficient Lighting in buildings: The lack of legislation in Portugal. **Energy Policy**, v. 67, jan. 2014, p. 82-86. 2014.
- ALTUN, A.; UGUR-ALTUN, B. Melatonin: therapeutic and clinical utilization. **International Journal of Clinical Practice**, v. 61, n. 5, p. 835-45. 2007.
- AMORIM, C. N. D. Diagrama Morfológico Parte I - Instrumento de análise e projeto ambiental com uso de luz natural. **Paranoá (UnB)**, v. 3, p. 57-76. 2007.
- _____. Diagrama Morfológico Parte II - Projetos exemplares para a luz natural: treinando o olhar e criando repertório. **Paranoá (UnB)**, v. 3, p. 77-97. 2007.

- ANDERSEN, M.; KLEINDIENST, S.; GAGNE, J. M. L. **LIGHTSOLVE TUTORIAL**. Building Technology Program, MIT Department of Architecture, p. 39. 2010
- ANDRADE, A. L.; *et al.* **Pensamento Sistêmico - caderno de campo: O desafio da mudança sustentada nas organizações e na sociedade**:Porto Alegre: Bookman. 2006
- AQLAN, F., *et al.* **Integrating Artificial Neural Networks and Cluster Analysis to Assess Energy Efficiency of Buildings**.In: Proceedings of the 2014 Industrial and Systems Engineering Research Conference, 2014. 8 p.
- ARASTEH, D.; JOHNSON, R.; SELKOWITZ, S. **Definition and Use of a Daylight "Coolness" Index**.In: 1986 International Daylighting Conference. Long Beach: American Society of Heating, Refrigerating and Air-Conditioning Engineers, INC. p. 134-141, 1986.
- ARDAKANI, F. J.; ARDEHALI, M. M. Novel effects of demand side management data on accuracy of electrical energy consumption modeling and long-term forecasting. **Energy Conversion and Management**, v. 78, p. 745-752. 2014.
- ARDEHALI, M. M. **Artificial intelligence for energy auditing of influential design elements based on electrical energy data**. In: World Energy Engineering Congress 2011, WEEC 2011. Chicago. p. 370-380. 2011.
- ARDEHALI, M. M.; FARMAD, M.; ADAMS, C. C. Development of pattern recognition based ANN for energy auditing and inefficiency diagnostics of influential design elements utilizing electrical energy data. **Journal of the Energy Institute**, v. 83, n. 2, p. 101-107. 2010.
- ARIA, H.; AKBARI, H. Integrated and multi-hour optimization of office building energy consumption and expenditure. **Energy and Buildings**, v. 82, p. 391-398. 2014.
- ASCHEHOUG, O. Daylighting in Glazed Spaces: Daylighting in Long Glazes Streets Examined With Physical Models in an Artificial Sky and Computer Simulations. **Building Research and Information**, v. 20, n. 4. 1992.
- ASE. Swiss Norm SN 418911. **Schweizerischer Elektrotechnischer Verein (Sev)**. SN 418911. Association Suisse des Electriciens.Zurich. 1989.
- ASHRAE. Standard 90.1 - Energy Standard for Buildings Except Low-Rise Residential Buildings **I. Ansi/Ashrae/Ies- American Society of Heating Refrigeration and Air-Conditioning Engineers**. 90.1. Atlanta. 1989.
- _____. Standard 90.1 - Energy Standard for Buildings Except Low-Rise Residential Buildings **I. Ansi/Ashrae/Ies- American Society of Heating Refrigeration and Air-Conditioning Engineers**. 90.1. Atlanta. 1999.
- _____. Standard 90.1 - Energy Standard for Buildings Except Low-Rise Residential Buildings - ANSI/ASHRAE/IESNA Apêndice G to ANSI/ASHRAE/IESNA Standard 90.1-2007. **I. Ansi/Ashrae/Ies- American Society of Heating Refrigeration and Air-Conditioning Engineers**. 90.1. Atlanta. 2007.
- _____. Standard 90.1 - Energy Standard for Buildings Except Low-Rise Residential Buildings. **I. Ansi/Ashrae/Ies- American Society of Heating Refrigeration and Air-Conditioning Engineers**. 90.1. Atlanta. N. 221. 2010.

- _____. Standard 90.1 - Energy Standard for Buildings Except Low-Rise Residential Buildings. **I. Ansi/Ashrae/Ies- American Society of Heating Refrigeration and Air-Conditioning Engineers**. 90.1. Atlanta. N. 174.2 013.
- ASRHAE. Standard method of test of the evaluation of building energy analysis computer program. **I. Ansi/Ashrae/Ies- American Society of Heating Refrigeration and Air-Conditioning Engineers**. Asrhae Standard 140. Atlanta. N. 91. 2001.
- ASSAF, L. O.; PEREIRA, F. O. R. **Perspectivas de la eficiência energética en la iluminación: desafios para el desarrollo**. VII ENCAC -Encontro Nacional sobre Conforto no Ambiente Construído e III COTEDI - Conferência Latino Americana sobre Conforto e Desempenho Energético nas Edificações. Curitiba 2003.
- ATANASIO, V.; PEREIRA, F. O. R.; PEREIRA, A. T. C. **Laboratório Experimental para Ensino de Iluminação em Arquitetura através de um AVA**. In: Congresso Nacional de Ambientes Hiperfótona para Aprendizagem. Florianópolis: CONAHPA. 09 a 13 de abril, 2006. 10 p.
- BABINI, M. **Reconhecimento de Padrões Lexicais por meio de Redes Neurais**. (dissertação de mestrado). Departamento de Engenharia Elétrica, Universidade Estadual Paulista, Faculdade de Engenharia de Ilha Solteira, Ilha Solteira, 2006. 110 p.
- BAKER, M. **Daily Cycle of Radiation and Temperature**. The COMET Program Disponível em: < www.meted.ucar.edu >. Acesso em julho de 2013.
- BAKER, N.; FANCHIOTTI, A.; STEEMERS, K. **Daylighting in architecture – a European reference book**. 1st. London: Commission of the European Communities, Directorate - General XII for Science Research and Development: James & James Ltd 1993. 380 p.
- BAKER, N. e STEEMERS, K. **Energy and Environment in Architecture: A technical Design Guide**: Oxon: Tylor and Francis. 2000. 224 p.
- _____. **Daylight Design of Buildings**: London: James & James. 2002. 236 p.
- BARTLETT, J. E.; KOTRLIK, J. W.; HIGGINS, C. C. Organizational Research: Determining Appropriate Sample Size in Survey Research. **Information Technology, Learning, and Performance Journal**, v. 19, n. 1, mar-jun de 2001, p. 43-50. 2001.
- BEAUCHEMIN, K. M.; HAYS, P. Sunny hospital rooms expedite recovery from severe and refractory depressions **Journal of Affective Disorders**, v. 40, n. 1-2, p. 49-51. 1996.
- BLANNING, R. The Construction and Implementation of Metamodels. **Simulation**, v. 24, p. 177-184. 1975.
- BOCANEGRA, C. W. R. **Procedimento para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes**. (dissertação de mestrado). Departamento de Engenharia Civil, Universidade de São Paulo, São Carlos, 2002. 97 p.
- BODART, M.; DE HERDE, A. Global energy savings in offices buildings by the use of daylighting. **Energy and Buildings**, v. 34, n. 5, p. 421-429. 2002.
- BOGO, A. J. **Método para avaliação da admissão de luz natural através de aberturas com elementos de controle solar**. Departamento de Engenharia Civil, Universidade Federal de Santa Catarina, Florianópolis, 2007. 308 p.

- BOURGEOIS, D.; REINHART, C.; MACDONALD, I. Adding advanced behavioral models in whole building energy simulation: A study on the total energy impact of manual and automated lighting control. **Energy and Buildings**, v. 38, n. 7, p. 814-823. 2006.
- BOURGEOIS, D.; REINHART, C. F.; WARD, G. Standard daylight coefficient model for dynamic daylighting simulations. **Building Research and Information**, v.3 6, n. 1, p. 68-82. 2008.
- BPIE. **Europe's buildings under the microscope: A country-by-country review of the energy performance of buildings**. Buildings Performance Institute Europe Brussels. 2011. 131 p.
- BRAGA, A. P.; LUDEMIR, T. B.; CARVALHO, A. C. P. L. F. **Redes neurais artificiais, teoria e aplicações**: Rio de Janeiro: Livros Técnicos e Científicos Editora S. A. 2000. 262 p.
- BRASIL. Decreto n. 4.059, de 19 de dezembro de 2001. Regulamenta a Lei n. 10.295, de 17 de outubro de 2001, que dispõe sobre a Política Nacional de Conservação de Energia, e dá outras providências. **Brasil**. Lex: Diário Oficial da União, Brasília. 2001a.
- _____. Lei n. 10.295, de 17 de outubro de 2001. Dispõe sobre a Política Nacional de Conservação e Uso Racional de Energia. **Brasil**. Lei n. 10.295. Lex: Diário Oficial da União, Brasília. 2001b.
- BRASIL, M. M. E. **Plano Nacional de Energia 2030 - Eficiência Energética**: Ministério de Minas e Energia, Empresa de Pesquisa Energética. 2007. 242 p.
- BROWN, G. Z.; DEKAY, M. **Sol, Vento & Luz - Estratégias para o Projeto de Arquitetura**. 2nd: São Paulo: Bookman. 2004. (Tradução: Salvaterra, A. F. S.) 415 p.
- BURATTI, C.; BARBANERA, M.; PALLADINO, D. An original tool for checking energy performance and certification of buildings by means of Artificial Neural Networks. **Applied Energy**, v. 120, p. 125-132. 2014.
- CALDAS, L. Generation of energy-efficient architecture solutions applying GENE_ARCH: An evolution-based generative design system. **Advanced Engineering Informatics**, v. 22, n. 1, p. 59-70. 2008.
- CALDAS, L. G.; NORFORD, L. K. A design optimization tool based on a genetic algorithm. **Automation in Construction**, v. 11, n. 2, p. 173-184. 2002.
- CALIFORNIA ENERGY COMMISSION. TITLE 24 - 2013 Building Energy Efficiency Standards for Residential and Nonresidential Buildings CEC-400-2012-004-CMF-REV2. California Energy Commission. Part 1. N. 252. 2013.
- CAPOZZOLI, A.; MECHRI, H. E.; CORRADO, C. **Impacts of Architectural Design Choices on Building Energy Performance Applications of Uncertainty and Sensitivity Techniques**. In: Eleventh International IBPSA Conference. Glashow: IBPSA. 27 a 30 de julho, 2009. p. 1000-1007, 2009.
- CARLO, J.; PEREIRA, F. O. R.; LAMBERTS, R. **Iluminação natural para redução do consumo de energia de edificações de escritório aplicando propostas de eficiência energética para o código de obras do Recife**. Encontro Nacional de Tecnologia no Ambiente Construído. São Paulo. 2004.

- CARLO, J. C. **Desenvolvimento de Metodologia de Avaliação da Eficiência Energética do Envoltório de Edificações Não-Residenciais**. Engenharia Civil, Universidade Federal de Santa Catarina, Florianópolis, 2008. 182 p.
- CASTILLA, M.; *et al.* Técnicas de Control del Confort en Edificios. **Revista Iberoamericana de Automática e Informática Industrial RIAI**, v. 7, n. 3, p. 5-24. 2010.
- CERTI. **S3e: Simulador de Eficiência Energética em Edificações**. LabEEE - Universidade Federal de Santa Catarina Disponível em: <<http://www.s3e.ufsc.br/saveRegister>>. Acesso em: maio de 2014.
- CHAN, Y.-C.; TZEMPELIKOS, A. Efficient venetian blind control strategies considering daylight utilization and glare protection. **Solar Energy**, v. 98, Part C, p. 241-254. 2013.
- CHANG, M.-C.; SHIH, S.-G. A Hybrid Approach of Dynamic Programming and Genetic Algorithm for Multi-criteria Optimization on Sustainable Architecture design. **Computer-Aided Design and Applications**, v. 12, n. 3, 29 de janeiro de 2015. p. 310-319. 2015.
- CHIDIAC, S. E.; *et al.* A screening methodology for implementing cost effective energy retrofit measures in Canadian office buildings. **Energy and Buildings**, v. 43, p. 614-620. 2011.
- CHOI, J.-H.; BELTRAN, L. O.; KIM, H.-S. Impacts of indoor daylight environments on patient average length of stay (ALOS) in a healthcare facility. **Building and Environment**, v. 50, p. 65-75. 2012.
- CHOW, T. T.; *et al.* Global optimization of absorption chiller system by genetic algorithm and neural network. **Energy and Buildings**, v. 34, n. 1, p. 103-109. 2002.
- CHUNG, W.; HUI, Y. V.; LAM, Y. M. Benchmarking the energy efficiency of commercial buildings. **Applied Energy**, v. 83, p. 1-14. 2006.
- CIBSE. **Lighting Guide 10: Daylighting and Window Design**. Chartered Institution of Building Services Engineers. Londres. 1999. 88 p.
- CIE. TC 6-11. Draft "Ocular Lighting Effects on Human Physiology, Mood and Behavior". **Commission Internationale d'Eclairage**. 2003.
- _____. Spatial distribution of daylight - CIE standard general sky. **Commission Internationale d'Eclairage** 2 Rule. ISO 15469/ CIE S 011/. Commission Internationale de l'Eclairage. 2004.
- _____. Ocular lighting effects on human physiology, mood, and behavior (CIE 158:2004) - ERRATUM (2009-Jan-21) **Commission Internationale d'Eclairage**. 2009.
- CLARO, A. **Modelo vetorial esférico para radiosidade aplicado à iluminação natural**. . Departamento de Engenharia de Produção, Universidade Federal de Santa Catarina, Florianópolis, 1998. 178 p.
- _____. **Luz solar: modelo vetorial esférico para radiosidade/ray-tracing**. In: Encontro Latino Americano de Conforto no Ambiente Construído, 2º & Encontro Nacional de Conforto no Ambiente Construído, 5º. Fortaleza, 1999.
- _____. **INDELPA- Light Tool**. o programa combina os cálculos de iluminação artificial com a luz natural, propiciada pelas aberturas existentes e por sua localização em relação ao Sol. Florianópolis. 2008. Disponível em: <<http://indelpa-iluminacao.software.informer.com/>>. Acesso em: março de 2014

- COAKLEY, D.; RAFTERY, P.; KEANE, M. A review of methods to match building energy simulation models to measured data. **Renewable and Sustainable Energy Reviews**, v. 37, p. 123-141. 2014.
- COLACO, S. G.; *et al.* **An adaptive predictive framework to online prediction of interior daylight illuminance**. In: Proceedings of the 2014 International Conference on Advances in Energy Conversion Technologies - Intelligent Energy Management: Technologies and Challenges, ICAECT 2014. p. 174-180. Manipal, 2014.
- ÇOLAK, N.; ONAYGIL, S. Prediction of the artificial illuminance using neural networks **Lighting Research and Technology**, v. 31, n. 2, 13 nov 1998, p. 63-69. 1999.
- COLEY, D. A.; SCHUKAT, S. Low-energy design: combining computer-based optimization and human judgment. **Building and Environment**, v. 37, n. 12, p. 1241-1247. 2002.
- COMMISSION OF THE EUROPEAN COMMUNITIES. **Daylighting in Architecture - A European Reference Book**: London 1993
- CONGRADAC, V.; KULIC, F. Recognition of the importance of using artificial neural networks and genetic algorithms to optimize chiller operation. **Energy and Buildings**, v. 47, p. 651-658. 2012.
- CORPORATION, A. E. **SPOT: Sensor Placement +Optimization Tool**. Quantifies existing or intended electric lighting performance, evaluate annual daylighting characteristics and help establish the optimal photosensor placement in a given space relative to annual performance and annual energy savings. Boulder. 2011. Disponível em: <http://apps1.eere.energy.gov/buildings/tools_directory/software.cfm/ID=471/page_name=alpha_list_sub>. Acesso em: março de 2014.
- CORREA, M. V.; AGUIRRE, L. A. Identificação Não-Linear Caixa-Cinza: uma Revisão e Novos Resultados. **Revista Controle e Automação**, v. 15, n. 2, abr. a jun., p.109-126. 2004.
- COSTA, G. C. F. **Uma avaliação do consumo de energia com transportes em cidades do estado de São Paulo**. (dissertação de mestrado). Departamento de Engenharia Civil, Universidade de São Paulo, São Carlos, 2001. 103 p.
- COSTA, S. M. S. Metodologia de Sistemas Flexíveis aplicada a estudos em Ciências da Informação: uma experiência pedagógica. **Transinformação**, v. 15, n. 2, mai./agos., p. 259-271. 2003.
- CRAWLEY, D. B.; *et al.* **Contrasting the capabilities of building energy performance simulation program**. US Department of Energy, University of Strathclyde, University of Wisconsin-Madison, National Renewable Energy. Washington DC: julho de 2005. 2005. 59 p.
- _____. EnergyPlus: creating a new-generation building energy simulation program. **Energy and Buildings**, v. 33, n. 4, p. 319-331. 2001.
- CREATIVE COMMONS. **Diagrama de caixa box plot**. Wikimedia Commons. Disponível em: <http://commons.wikimedia.org/wiki/File:Diagrama_de_caixa_box_plot.png>. Acesso em: março de 2014.

- CSBR; LBNL. **Façade Design Tool** U. D. O. Energy. This tool is intended for use in the early part of the design process to understand the impacts of various design decisions. You choose the design conditions of a facade and rank and/or compare the performance data in terms of annual energy, peak demand, carbon, daylight illuminance, glare, and thermal comfort. Minneapolis.2012.Disponível em: <<http://www.commercialwindows.org/fdt.php>>. Acesso em: março de 2014.
- D.O.E -US. **EnergyPlus**.v. 6. Programa de análise termoenergética detalhada. 2012.
- DATTA, D.; TASSOU, S. A. Artificial neural network based electrical load prediction for food retail stores. **Applied Thermal Engineering**, v. 18, n. 11, p. 1121-1128. 1998.
- DAVIDSON, S. **Grasshopper: Algorithmic modeling for Rhino**. v. 1.0 para Rhino 5.2014
- DE BOER, J.; ERHORN, H. **Survey Simple Design Tools**. International Energy Agency (IEA) Solar Heating and Cooling Programme, Energy Conservation in Buildings & Community Systems - TASK 21. Stuttgart, p.49. 1999
- DE WILDE, P. The gap between predicted and measured energy performance of buildings: A framework for investigation. **Automation in Construction**, v. 41, p. 40-49. 2014.
- DEMIR, A.; KONAN, N. Impact of Daylighting on Student and Teacher Performance. **Journal of Educational and Instructional Studies in the World**, v.3, n.1, fev./mar./abr. 2013. 7 p.
- DIDONÉ, E. L. **A influência da luz natural na avaliação da eficiência energética de edifícios contemporâneos de escritórios em Florianópolis/SC**. . Arquitetura e Urbanismo, Universidade Federal de Santa Catarina, Florianópolis, 2009. 174 p.
- DIDONÉ, E. L.; PEREIRA, F. O. R. Simulação computacional integrada para a consideração da luz natural na avaliação do desempenho energético de edificações. **Revista Ambiente Construído**, v. 10, n. 4, out/2010. 2010, 15 p.
- DOULOS, L.; TSANGRASSOULIS, A.; TOPALIS, F. Quantifying energy savings in daylight responsive systems: The role of dimming electronic ballasts. **Energy and Buildings**, v. 40, n. 1, p. 36-50. 2008.
- DOUNIS, A. I.; CARAISCOS, C. Advanced control systems engineering for energy and comfort management in a building environment - A review. **Renewable and Sustainable Energy Reviews**, v.13, n.6-7, agosto/setembro, p.1246-1261. 2009.
- DUCH, W.; JANKOWSKI, N. New neural transfer functions. **International Journal of Applied Mathematics and Computer Science**, v. 7, p. 639 -658. 1997.
- DUFTON, A. F. The computation of Daylight Factors in factory design. **Journal of Sci.Instr.**, v. 17, n. 9, p. 226-227. 1940.
- _____. Protractors for the computation of Daylight Factor. B. R.S. **Techn. H.M.S.O**. 1946. 28p.
- EDWARDS, L.; TORCELLINI, P. **A Literature Review of the Effects of Natural Light on Building Occupants**. National Renewable Energy Laboratory. Golden, Colorado: 2002. 2002, 54 p. (NREL/TP-550-30769)
- EDWARDS, R. E.; NEW, J.; PARKER, L. E. Predicting future hourly residential electrical consumption: A machine learning case study. **Energy and Buildings**, v.49, p. 591-603. 2012.

- EKICI, B. B.; AKSOY, U. T. Prediction of building energy consumption by using artificial neural networks. **Advances in Engineering Software**, v. 40, n. 5, p. 356-362. 2009.
- ENERGY DESIGN RESOURCES. **Design Brief: Understanding Daylight Metrics**. Energy Design Resources, 2008.
- ENERGYPLUS. **Getting Started with EnergyPlus. Basics concept manual - Essential information you need about running EnergyPlus**. California/USA: Ernest Orlando Lawrence Berkeley National Laboratory: 2010. 75 p.
- ENLIGHTEN. **DAYLIGHTING METRICS — Defining Successful Daylighting**.enLighten - The Bimonthly Newsletter of the Daylighting Collaborative. Disponível em: <http://www.ecw.org/sites/default/files/enlighten_Aug08.pdf>. Acesso em: 24 de janeiro de 2015.3
- EPBD-NCM. **National Calculation Methodology (NMC) modeling guide (for buildings other than dwellings in England)**: Department for Communities and Local Government: 2014. 55 p.
- EPE. **Balço Energético Nacional 2014**. Empresa de Pesquisa Energética - Ministério de Minas e Energia. Brasília: ano base 2013. 2014, p.285.
- ERHORN, H.; STOFFEL, J. **ADELIN 2.0 User's Manual**. Stuttgart. 1996
- ESCRIVÁ-ESCRIVÁ, G.; *et al.* New artificial neural network prediction method for electrical consumption forecasting based on building end-uses. **Energy and Buildings**, v. 43, n. 11, p. 3112-3119. 2011.
- EVINS, R. A review of computational optimization methods applied to sustainable building design. **Renewable and Sustainable Energy Reviews**, v. 22, p. 230-245. 2013.
- FELIPPE, A. R.; *et al.* **Modelagem paramétrica para simulação do desempenho da iluminação natural e termoenergético da edificação**. XIX SIGraDi - XIX Congresso da Sociedade Ibero-Americana de Gráfica Digital. Florianópolis, 23 a 27 de novembro de 2015. In: São Paulo: Blucher, 2015. p. 398-404. 2015
- FERREIRA, D. D.; *et al.* Sistema automático de detecção e classificação de distúrbios elétricos em qualidade da energia elétrica. **Sba: Controle & Automação Sociedade Brasileira de Automática**, v. 20, n. 1, janeiro/março. 2009.
- FERREIRA, P. M.; *et al.* Neural networks based predictive control for thermal comfort and energy savings in public buildings. **Energy and Buildings**, v. 55, p. 238-251. 2012.
- FERREIRA, V. H. **Técnicas de Regularização de Modelos Neurais Aplicadas à Previsão de Carga a Curto Prazo**. (Dissertação de mestrado). Departamento de Engenharia Elétrica, UFRJ - COPPE, Rio de Janeiro, 2005. 204 p.
- FIUZA, J. M. **Influência de elementos de proteção solar horizontais aplicados à aberturas laterais, na admissão e distribuição da luz natural**. . Arquitetura e Urbanismo, Universidade Federal de Santa Catarina, Florianópolis, 2008. 183 p.
- FONSECA, R. W. **A influência das reflexões internas como contribuição da iluminação natural no ambiente construído**. Arquitetura e Urbanismo, Universidade Federal de Santa Catarina, Florianópolis, 2007. 167 p.
- FONSECA, R. W., *et al.* **Development of a Daylighting Index for Window Energy Labeling and Rating System for Residential Buildings in Brazil**. In: 13th Conference of International Building Performance Simulation Association. Chambéry: IBPSA. 26 a 28 de agosto de 2013. p. 3002-3009. 2013.

- FOUCQUIER, A., *et al.* State of the art in building modeling and energy performances prediction: A review. **Renewable and Sustainable Energy Reviews**, v. 23, p. 272-288. 2013.
- FUMO, N. A review on the basics of building energy estimation. **Renewable and Sustainable Energy Reviews**, v. 31, p. 53-60. 2014.
- FUMO, N., MAGO, P. e LUCK, R. Methodology to estimate building energy consumption using EnergyPlus Benchmark Models. **Energy and Buildings**, v. 42, n. 12, p. 2331-2337. 2010.
- GALATIOTO, A.; BECCALI, M.; MILONE, D. **Sustainable lighting design through the analysis of spatial and time non uniformities in natural lighting with the metric of the information theory**. In: 9th Conference on Sustainable Development of Energy, Water and Environment Systems. Venice-Istanbul SDEWES: SDEWES. 20 a 27 de setembro de 2014, 2014. 11 p.
- GERMAN INDUSTRIAL STANDARD. DIN 5034 - Daylight in Interiors, part 3, Calculation. **Deutsches Institut Für Normung**. DIN 5034 -1994-09.1994a.
- _____. DIN 5034 - Daylight in Interiors, part 4, Simplified determination of window sizes for dwellings. **Deutsches Institut Für Normung**. DIN 5034.1994b.
- _____. DIN 4034 - Daylight in Interiors - Part 6: Simplified determination of suitable dimensions for roof lights. **Deutsches Institut Für Normung**. DIN 4034. 1996.
- _____. DIN 4034 - Daylight in Interiors - Part 6: Simplified determination of suitable dimensions for roof lights. **Deutsches Institut Für Normung**. DIN 4034. 2007a.
- _____. DIN 5034 - Daylight in Interiors, part 3, Calculation. **Deutsches Institut Für Normung**. DIN 5034 -2007. Number18. 2007b.
- GHISI, E. **The use of fiber optics on energy efficient lighting in buildings**. (tese de doutorado). School of Civil Engineering, University of Leeds, Leeds, Inglaterra, 2002. 295 p.
- GHISI, E.; TINKER, J. A. Potencial de economia de energia em iluminação através da utilização de fibras ópticas. **Revista Ambiente Construído**, v. 4, n. 3, jul/set 2004. 2004. p. 17.
- GHISI, E.; TINKER, J. A.; IBRAHIM, S. H. Área de janela e dimensões de ambientes para iluminação natural e eficiência energética: literatura versus simulação computacional. **Revista Ambiente Construído**, v. 5, n. 4, out/dez 2005. 2005. p. 13
- GIBSON, T. A. **Daylighting Software Validation Study and Development of a Simplified Method to Predict the Energy Impacts of Façade Design and Daylighting Control in Private Offices**. (dissertação de mestrado). Departamento de Engenharia Civil, Ambiental e Arquitetônica: Sistemas de Edifícios, University of Colorado, Boulder, 2011. 273 p.
- GMBH, D. **DIALux evo**. A light planning program for calculation and visualization of indoor and outdoor lighting systems. .Lüdenscheid 2014. Disponível em: <<http://www.dial.de/DIAL/en/dialux/download/dialux-evo.html>>. Acesso em: dezembro de 2014.
- GOLAY, Y.; *et al.* **Typological study on the influence of main daylighting design parameters**. - Developed in the LUMEN Program, Grojet CERS 2264.2, Project NEFF 435.3. EPFL, CH-1015. Lausanne. 1994

- GONZÁLEZ, P. A.; ZAMARREÑO, J. M. Prediction of hourly energy consumption in buildings based on a feedback artificial neural network. **Energy and Buildings**, v. 37, n. 6, p. 595-601. 2005.
- GRAU, K.; WITTCHEN, K. B. **Building Design System and CAD Integration**. In: International IBPSA Building Simulation Conference 1999. Kyoto, Japan: IBPSA. 13 a 15 de setembro de 1999. Artigo A – 30, 8 p.
- GROOT, E.; ZONNEVELDT, L.; PAULE, B. **DIAL Europe: A Decision Support Tool for Early Lighting Design**. In: 8TH International IBPSA Conference Building Simulation. Eindhoven, Netherlands: IBPSA, 2003. p. 421-426. 2003.
- GUILLEMIN, A.; MOREL, N. An innovative lighting controller integrated in a self-adaptive building control system. **Energy and Buildings**, v. 33, n. 5, p. 477-487. 2001.
- _____. Experimental results of a self-adaptive integrated control system in buildings: a pilot study. **Solar Energy**, v. 72, n. 5, p. 397-403. 2002.
- HAGHIGHAT, F.; MARSH, A. **The application of the computer-optimized solutions to tightly defined design problems. PLEA- Passive Low Energy Architecture**. Eindhoven/ Holanda: PLEA 2004.
- HAMDY, M.; HASAN, A.; SIREN, K. Applying a multi-objective optimization approach for Design of low-emission cost-effective dwellings. **Building and Environment**, v. 46, n. 1, p. 109-123. 2011.
- _____. A multi-stage optimization method for cost-optimal and nearly-zero-energy building solutions in line with the EPBD-recast 2010. **Energy and Buildings**, v. 56, p. 189-203. 2013.
- HAYKIN, S. **Redes Neurais: Princípios e Práticas.2**:Porto Alegre: ARTMED Editora S.A. 2001. 900 p.
- HECHT-NIELSEN, R. **Kolmogorov's mapping neural network existence theorem**. In: Proceedings IEEE International Conference On Neural Networks. San Diego: SOS Printing. 18 a 29 de junho, 1987. p. 11-14. 1987.
- HENRIQUES, G. A. C.; DUARTE, J. P.; LEAL, V. Strategies to control daylight in a responsive skylight system. **Automation in Construction**, v. 28, p. 91-105. 2012.
- HENSEN, J. L. M. **Overview of simulation**. USA: IBPSA-International Building Performance Simulation. 2006. 144 p.
- HESHONG, L. **Daylight and Retail Sales**. Heschong Mahone Group - Public Interest Energy Research - California Energy Commission. Fair Oaks: outubro de 2003. 2003a. (P500-03-082-A-5). 72 p.
- _____. **Window and Offices: A study of Office Worker Performance and the Indoor Environment**. Heschong Mahone Group - Public Interest Energy Research - California Energy Commission. Fair Oaks: outubro 2003. 2003b. (P500-03-082-A-9). 143 p.
- _____. **Windows and Classrooms: A Study of Student Performance and the Indoor Environment**. Heschong Mahone Group - Public Interest Energy Research - California Energy Commission. Fair Oaks: outubro de 2003. 2003c. (P500-03-082-A-7). 111 p.

- _____. **Daylight Metrics**. Heshong Mahone Group - Public Interest Energy Research - California Energy Commission fevereiro de 2012, 2011. (CEC-500-2012-053), 387 p.
- HESHONG, L.; SAXENA, M.; HIGA, R. **Improving Prediction of Daylighting Performance**. In: Proceedings of the ACEEE Summer Study 2010 on Energy Efficiency in Buildings. Asilomar: Washington (DC): American Council for an Energy-Efficient Economy. p. 103 - 116 p. 2010
- HITCHCOCK, R.; OSTERHAUS, W. **SUPERLITE 2.0 User's Manual**. Lawrence Berkeley Laboratory, Berkeley. 1993. (LBL-32946)
- HONG, T.; KOO, C.; PARK, S. A decision support model for improving a multi-family housing complex based on CO2 emission from gas energy consumption. **Building and Environment**, v. 52, p. 142-151. 2012.
- HOPFE, C. J.; *et al.* **Uncertainty Analysis for Building Performance Simulation – A Comparison of Four Tools**. In: Proceedings of the 10th IBPSA Building Simulation Conference. Beijing: IBPSA. Setembro de 2007. P. 1383-1388. 2007
- HOPKINSON, R. G.; LONGMORE, J.; PETHERBRIDGE, P. An Empirical Formula for the Computation of Indirect Component of the Daylight Factor. **Transactions of the Illuminating Engineering Society**, v. 19, n. 7, p. 201-219. 1954.
- HOPKINSON, R. G.; PETHERBRIDGE, P.; LONGMORE, J. **Daylighting**: London. 1966
- HU, J.. OLBINA, S. Illuminance-based slat angle selection model for automated control of split blinds. **Building and Environment**, v. 46, n. 3, p. 786-796. 2011.
- HUNT, D. R. G. The Use of Artificial Lighting in Relation to Daylight Levels and Occupancy. **Building an Environment**, v. 14, 1979, 13 p.
- _____. Predicting artificial lighting use- a method based upon observed patterns of behavior. **Lighting Research and Technology**, v. 12, 18 de jun. de 1980. 1980. 8p.
- HVIID, C. A., NIELSEN, T. R. e SVENDSEN, S. Simple tool to evaluate the impact of daylight on building energy consumption. **Solar Energy**, v. 82, n. 9, p. 787-798. 2008.
- IEA. **Daylight in Buildings: A Source Book on Daylighting Systems and Components** Berkeley International Energy Agency (IEA) Solar Heating and Cooling Programme, Energy Conservation in Buildings & Community Systems - TASK 21. 2000.
- IES. **IES Virtual Environment (IESVE): VE-Gaia** VE-Gaia is IES' architectural analysis tool. Its step-by-step workflow system demystifies simulation and allows users to progress from earlier ballpark comparisons into detailed early-stage calculations across: Climate, Bioclimate, Natural resource availability, Building & material characteristics, Solar Shading, Water reduction, Daylighting, Energy, Carbon, Heating/cooling loads, and Potential efficient & renewable technologies.Glasgow.2010.Disponível em: <<http://www.iesve.com/>>.Acesso em: julho de 2014.
- IES. **Approved Method: IES Spatial Daylight Autonomy (sDA) and Annual Sunlight Exposure (ASE) - IES LM-83-12**. Illuminating Engineering Society of North America. Nova Iorque. 2012. 12 p.

- IHM, P.; NEMRI, A.; KRARTI, M. Estimation of lighting energy savings from daylighting. **Building and Environment**, v. 44, n. 3, p. 509-514. 2009.
- ILB; FIBP. **MS-EXCEL spreadsheets for basic equations commonly used in daylighting**. Institut für Licht- und Bautechnik an der Fachhochschule Köln, Fraunhofer Institute for Building Physics. Köln / Stuttgart:
- INMETRO. Requisito técnico da qualidade para o nível de eficiência energética de edifícios comerciais, de serviços e públicos. **I. E. C. E. Ministério Do Desenvolvimento**. 2Rule.Portaria n. 372.INMETRO. N. 87.2010.
- _____. Requisitos de Avaliação da Conformidade para Eficiência Energética de Edificações: Anexo Geral V - Catálogo de propriedades térmicas de paredes, coberturas e vidros. **Ministério Do Desenvolvimento Indústria E Comércio Exterior**.Portaria n. 50.INMETRO. N. 101.2013.
- IVERSEN, A.; *et al.* **Daylight calculations in practice: An investigation of the ability of nine daylight simulation programs to calculate the daylight factor in five typical rooms**. Danish Building Research Institute - Alborg University Copenhagen. Copenhagen. 2013. (SBI 2013:26). 54 p.
- JACOME, C. R. F. **Uso de Conhecimento Prévio na Identificação de Modelos Polinomiais NARMAX**. Departamento de Engenharia Elétrica, UFMG, Belo Horizonte, 1996. 161 p.
- JAIN, R. K., *et al.* Forecasting energy consumption of multi-family residential buildings using support vector regression: Investigating the impact of temporal and spatial monitoring granularity on performance accuracy. **Applied Energy**, v. 123, p. 168-178. 2014.
- JAKUBIEC, J. A.; REINHART, C. **The Adaptive Zone – A Concept for Assessing Glare Throughout Daylit Spaces**. In: Proceedings of Building Simulation, 12th Conference of International Building Performance Simulation Association. p. 14-16. Sydney, 2011.
- JANJAI, S.; PLAON, P. Estimation of sky luminance in the tropics using artificial neural networks: Modeling and performance comparison with the CIE model. **Applied Energy**, v. 88, p. 840-847. 2011.
- JARDIM, C. S.; *et al.* **O potencial dos sistemas fotovoltaicos interligados à rede elétrica em áreas urbanas: dois estudos de caso**. ENCONTRO DE ENERGIA NO MEIO RURAL. Disponível em: <http://www.proceedings.scielo.br/scielo.php?pid=MSC0000000022004000200029&script=sci_arttext>. Acesso em 23 de janeiro de 2015. 12 p.
- JEONG, K.; KOO, C.; HONG, T. An estimation model for determining the annual energy cost budget in educational facilities using SARIMA (seasonal autoregressive integrated moving average) and ANN (artificial neural network). **Energy**, v. 71, p. 71-79. 2014.
- JIMÉNEZ, M. J.; *et al.* **Data analysis methods for building energy performance characterization: context and CIEMAT experiences in applications to test campaigns in warm sunny weather** In: Workshop on High Performance Buildings - Design and Evaluation Methodologies. Brussels Institute for Energy and Transportation - European Commission, 2013. 12 p.
- JOHNSEN, K.; GRAU, K. **tsbi3. Computer program for thermal simulation of buildings. User's Guide**. The Danish Building Research Institute. Horsholm. 1994.

- JUNG, H. C.; KIM, J. S.; HEO, H. Prediction of building energy consumption using an improved real coded genetic algorithm based least squares support vector machine approach. **Energy and Buildings**, v. 90, p. 76-84. 2015.
- KALOGIROU, S. A. Applications of artificial neural-networks for energy systems. **Applied Energy**, v.67, p. 17-35. 2000.
- _____. Artificial neural networks in renewable energy systems applications: a review. **Renewable and Sustainable Energy Reviews**, v.5, n.4, p.373-401. 2001.
- KALOGIROU, S. A.; BOJIC, M. Artificial neural networks for the prediction of the energy consumption of a passive solar building. **Energy**, v. 25, n. 5, p. 479-491. 2000.
- KALOGIROU, S. A.; *et al.* Artificial neural networks for the generation of a conductivity map of the ground. **Renewable Energy**, v.77, p.400-407. 2015.
- KAVAKLIOGLU, K.; *et al.* Modeling and prediction of Turkey's electricity consumption using Artificial Neural Networks. **Energy Conversion and Management**, v. 50, n. 11, p.2719-2727. 2009.
- KAZANASMAZ, T. Fuzzy logic model to classify effectiveness of daylighting in an office with a movable blind system. **Building and Environment**, v. 69, p. 22-34. 2013.
- KAZANASMAZ, T., GÜNAYDIN, M. e BINOL, S. Artificial neural networks to predict daylight illuminance in office buildings. **Building an Environment**, v. 44, p. 1751-1757. 2009a.
- _____. Artificial neural networks to predict daylight illuminance in office buildings. **Building and Environment**, v. 44, n. 8, p. 1751-1757. 2009b.
- KHAN, A. A.; LYE, L.; HUSAIN, T. Latin hypercube sampling for uncertainty analysis in multiphase modeling. **Journal of Environmental Engineering & Science**, v. 7, n. 6, p. 617-626. 2008.
- KILMER, R. A. **Artificial Neural Network Metamodels of Stochastic Computer Simulations**. (PhD). Escola de Engenharia, University of Pittsburgh, Pittsburgh, 1994. 234 p.
- KIM, J. T. e TODOROVIC, M. S. Tuning control of buildings glazing's transmittance dependence on the solar radiation wavelength to optimize daylighting and building's energy efficiency. **Energy and Buildings**, v. 63, p. 108-118. 2013.
- KNEIFEL, J. Beyond the code: Energy, carbon, and cost savings using conventional technologies. **Energy and Buildings**, v. 43, p. 951-959. 2011.
- KOLOKOTSA, D.; *et al.* 3.19 - Passive Solar Architecture. In: (Ed.). **Comprehensive Renewable Energy**. Oxford: Elsevier, 2012. 3.19 - Passive Solar Architecture, p. 637-665
- KOTA, S.; HABERL, J. S. **Historical Survey of Daylighting Calculations Methods and Their Use in Energy Performance Simulations**. In: Proceedings of the Ninth International Conference for Enhanced Building Operations. Austin, 17 a 19 de novembro, 2009. 9 p.
- KOUVELETSSOU, M.; *et al.* Simulating energy use and energy pricing in buildings: The case of electricity. **Energy and Buildings**, v. 54, p. 96-104. 2012.

- KRARTI, M. An Overview of Artificial Intelligence-Based Methods for Building Energy Systems. **Journal of Solar Energy Engineering**, v. 125, n. 3, agosto. 2003, p. 331-342. 2003.
- KRARTI, M.; ERICKSON, P. M.; HILLMAN, T. C. A simplified method to estimate energy savings of artificial lighting use from daylighting. **Building and Environment**, v. 40, n. 6, p. 747-754. 2005.
- KURIAN, C.; *et al.* Robust control and optimisation of energy consumption in daylight - artificial light integrated schemes. **Lighting Research and Technology**, v. 40, 27 fev 2007, p. 7-24. 2008.
- LABAYRADE, R.; *et al.* **Assessment of VELUX Daylight Visualizer 2 Against CIE 171:2006 Test Cases Test Cases 5.4 – 5.5 – 5.6 – 5.7 – 5.9 – 5.10 – 5.11 – 5.12 – 5.13 – 5.14.** VELUX. 2009. 72 p.
- LAGIUS, K.; NIEMASZ, J.; REINHART, C. **Animated Building Performance Simulation (ABPS) - Linking Rhinoceros/Grasshopper with Radiance/Daysim.** In: Proceedings of SimBuild 2010. Nova Iorque: IBPSA. 11 a 13 de agosto, 2010.
- LAPINSKIENE, V.; MARTINAITIS, V. The Framework of an Optimization Model for Building Envelope. **Procedia Engineering**, v. 57, p. 670-677. 2013.
- LBNL. **Building Design Advisor.3.1.** Windows computer program that addresses the needs of building decision-makers from the initial, schematic phases of building design through the detailed specification of building components and systems. .Berkeley.2006. Disponível em: <<http://gaia.lbl.gov/BDA/>>. Acesso em: março de 2014.
- _____. **COMFEN 4.1.L. B. Laboratory.** Berkeley.2012. Disponível em: <<https://windows.lbl.gov/software/comfen/comfen.html>>. Acesso em: março de 2014.
- LEDER, S. M.; PEREIRA, F. O. R.; MORAES, L. N. **Determinação Experimental de Coeficiente de Reflexão Médio para Superfícies Verticais em um Meio Urbano.** In: IX Encontro Nacional e V Latino Americano de Conforto no Ambiente Construído. Ouro Preto: ANTAC. 08 a 10 de outubro, 2007. p.1057-1065. 2007.
- LEPADATU, D.; JUDELE, L.; ROSU, A. **Applying Artificial Neural Networks to Estimate the Energy Performance of Buildings** In: Proceedings of Second Intl. Conf. on Advances In Civil, Structural and Environmental Engineering- ACSEE 2014. p. 267-272. 2014.
- LESLIE, R. P. Capturing the daylight dividend in buildings: why and how? **Building and Environment**, v. 38, n. 2, p. 381-385. 2003.
- LESO-PB. **DIAL+**.2.0. Lausanne. 2013. Disponível em: <<http://leso.epfl.ch/software/>>. Acesso em: dezembro de 2014.
- LI, D. H. W.; *et al.* Classification of CIE standard skies using probabilistic neural network. **Int J Climatol**, v. 30, n. 2, p. 305–315. 2010.
- LI, D. H. W.; TSANG, E. K. W. An analysis of daylighting performance for office buildings in Hong Kong. **Building and Environment**, v. 43, n. 9, p. 1446-1458. 2008.
- LI, D. H. W.; WONG, S. L.; CHEUNG, K. L. **Energy performance regression models for office buildings with daylighting controls.** In: 2008 Proceedings of the Institution

- of Mechanical Engineers, Part A: Journal of Power and Energy: SAGE, 2008. p. 557-568. 2008.
- LI, K.; SU, H.; CHU, J. Forecasting building energy consumption using neural networks and hybrid neuro-fuzzy system: A comparative study. **Energy and Buildings**, v. 43, n. 10, p. 2893-2899. 2011.
- LING, F. Y. Y.; LIU, M. Using neural network to predict performance of design-build projects in Singapore. **Building and Environment**, v. 39, n. 10, p. 1263-1274. 2004.
- LIU, H. **On the Levenberg-Marquardt training method for feed-forward neural networks**. In: 6th International Conference on Natural Computation. Yantai: ICNC. 10 a 12 de agosto, 2010. p. 456-460. 2010.
- LJUNG, L., Ed. **System Identification: Theory for the User**. Nova Jersey: Prentice Hall Inc. 1987. 238 p.
- LO VERSO, V. R. M.; PELLEGRINO, A.; PELLERREY, F. A multivariate non-linear regression model to predict the energy demand for lighting in rooms with different architectural features and lighting control systems. **Energy and Buildings**, v. 76, p. 151-163. 2014.
- LOFTNESS, V.; *et al.* **BUILDING INVESTMENT DECISION SUPPORT (BIDS™): Cost-Benefit Tool to Promote High Performance Components, Flexible Infrastructures and Systems Integration for Sustainable Commercial Buildings and Productive Organizations**. Carnegie Mellon University Center for Building Performance and Diagnostics. Pittsburgh. Disponível em: <http://www.aia.org/aiaucmp/groups/ek_public/documents/pdf/aiaip080050.pdf> Acesso em: 20 de janeiro de 2015. 2008. p. 29.
- _____. **The Triple Bottom Line Benefits of Climate-Responsive Dynamic Façades**. In: 30th International PLEA Conference - Passive and Low Energy Architecture. Ahmedabad, India: CEPT - University. 16-18 de dezembro de 2014. p. 187-196. 2014.
- LOGAR, V.; KRISTL, Z.; SKRJANC, I. Using a fuzzy black-box model to estimate the indoor illuminance in buildings. **Energy and Buildings**, v. 70, p. 343-351. 2014.
- LONGMORE, J. **B.R.S. Daylight protractors**. H.M.S.O. London. 1968. 25 p.
- LÓPEZ, G.; GUEYMARD, C. A. Clear-sky solar luminous efficacy determination using artificial neural networks. **Solar Energy**, v. 81, n. 7, p. 929-939. 2007.
- LOVE, J. A. **The Evolution of Performance Indicators for the Evaluation of Daylighting Systems** In: IEEE - Industry Applications Society Annual Meeting. Houston: IEEE. 4 a 9 de outubro, 1992. p. 1830-1836. 1992.
- LOVERSO, V. R. M.; REINHART, C. **Validation of the Lynes mean daylight factor formula and the daylight feasibility study in toplit spaces**. In: Proceedings of Lighting Quality & Energy Efficiency (CIE conference). Vienna: CIE. 17 de março, 2010. 13 p.
- LTD, D. S. **DesignBuilder**. It provides a range of environmental performance data such as: energy consumption, internal comfort data and HVAC component sizes. Output is based on detailed sub-hourly simulation time steps using the EnergyPlus simulation engine. Stroud. 2014. Disponível em: <<http://www.designbuilder.co.uk/>> Acesso em março de 2014.

- LU, T.; LÜ, X.; KIBERT, C. A hybrid numerical-neural-network model for building simulation: A case study for the simulation of unheated and uncooled indoor temperature. **Energy and Buildings**, v. 86, p. 723-734. 2015.
- LYNES, J. A sequence for daylighting design. **Lighting Research and Technology**, v. 11, p. 102-106. 1979.
- LYNES, J.; LITTLEFAIR, P. J. Lighting energy savings from daylight: estimation at the sketch design stage. **Lighting Research and Technology**, v. 22, n. 3, p. 129-137. 1990.
- MACDONALD, I.; STRACHAN, P. Practical application of uncertainty analysis. **Energy and Buildings**, v. 33, fev., p. 219-227. 2001.
- MACHAIRAS, V.; TSANGRASSOULIS, A.; AXARLI, K. Algorithms for optimization of building design: A review. **Renewable and Sustainable Energy Reviews**, v. 31, p. 101-112. 2014.
- MACKAY, D., J. C. Bayesian Interpolation **Neural Computation** v. 4, n. 3, p. 415-447 1992.
- MADSEN, K.; NIELSEN, H. B.; TINGLEFF, O. **METHODS FOR NON-LINEAR LEAST SQUARES PROBLEMS**. 2nd: Informatics and Mathematical Modelling, Technical University of Denmark 2004.
- MAGNIER, L.; HAGHIGHAT, F. Multiobjective optimization of building design using TRNSYS simulations, genetic algorithm, and Artificial Neural Network. **Building and Environment**, v. 45, n. 3, p. 739-746. 2010.
- MAGOULÈS, F.; ZHAO, H.-X.; ELIZONDO, D. Development of an RDP Neural Network for Building Energy Consumption Fault Detection Diagnosis. **Energy and Buildings**. 2013.
- MANUDHANE, R.; REINHART, C. **Daylighting Nomographs Revisited – Rules of Thumb to Predict Energy Savings from Photocell Controlled Dimming Systems**. In: SimBuild 2010 New York: IBPSA, 2010. 8 p.
- MARDALJEVIC, J. Simulation of annual daylighting profiles for internal illuminance. **Lighting Research and Technology**, v. 32, n. 2, 2000. 7 p.
- MARDALJEVIC, J.; *et al.* **Daylighting Metrics: Is There a Relation Between Useful Daylight Illuminance and Daylight Glare Probability? First Building Simulation and Optimization Conference**. Loughborough: IBPSA-England, p. 189-196, 2012.
- MARDALJEVIC, J.; HESCHONG, L.; LEE, E. Daylight metrics and energy savings. **Lighting Research & Technology**, v. 41, n. 3, p. 261-283. 2009.
- MARVUGLIA, A.; MESSINEO, A. Using Recurrent Artificial Neural Networks to Forecast Household Electricity Consumption. **Energy Procedia**, v. 14, p. 45-55. 2012.
- MASCHIO, C.; CARVALHO, C. P. V.; SCHIOZES, D. J. **Aplicação da técnica de hipercubo latino na integração do ajuste de histórico com a análise de incertezas. 5 Congresso Brasileiro de Pesquisa e Desenvolvimento em Petróleo e Gás**. Fortaleza/ Ceará: Associação Brasileira de P&D em Petróleo e Gás 2009.
- MASOSO, O. T.; GROBLER, L. J. A new and innovative look at anti-insulation behavior in building energy consumption. **Energy and Buildings**, v. 40, p. 1889-1894. 2008.

- MATOS, M. **Conceitos úteis: normalização e métricas**. Porto: Universidade do Porto, Faculdade de Engenharia [2012].
- MAVROMATIDIS, L. E.; MARSAULT, X.; LEQUAY, H. Daylight factor estimation at an early design stage to reduce buildings' energy consumption due to artificial lighting: A numerical approach based on Doehrlert and Boxâ€ Behnken designs. **Energy**, v. 65, p. 488-502. 2014.
- MAYHOUB, M. S.; CARTER, D. J. Towards hybrid lighting systems: A review. **Lighting Research & Technology**, v. 42, n. 1, p. 51-71. 2010.
- _____. The costs and benefits of using daylight guidance to light office buildings. **Building and Environment**, v. 46, n. 3, p. 698-710. 2011.
- MCNEEL, R.; ASSOCIATES. **Rhinoceros 3D.v. 5**. Rhinoceros 3D é um programa de modelagem tridimensional baseado na tecnologia NURBS. 2014
- MEISEL, W. S.; COLLINS, D. C. Repro-Modeling: An Approach to Efficient Model Utilization and Interpretation. **IEEE Systems, Man and Cybernetics Society**, v. 3, n. 4, julho p. 349-358. 1973.
- MELO, A. P. **Desenvolvimento de um método para estimar o consumo de energia de edificações comerciais através da aplicação de redes neurais**. (tese de doutorado). Departamento de Engenharia Civil, Universidade Federal de Santa Catarina, Florianópolis, 2012. 189 p.
- MELO, A. P.; *et al.* Development of surrogate models using artificial neural network for building shell energy labelling. **Energy Policy**, v. 69, p. 457-466. 2014.
- MENDES, N.; *et al.* Uso de instrumentos computacionais para análise do desempenho térmico e energético de edificações no Brasil. **Revista Ambiente Construído**, v. 5, n. 4, out/dez 2005. 2005. 22 p.
- MIHALAKAKOU, G.; SANTAMOURIS, M.; TSANGRASSOULIS, A. On the energy consumption in residential buildings. **Energy and Buildings**, v. 34, n. 7, p. 727-736. 2002.
- MINASNY, B. **Latin Hypercube Sampling**. This is sampling utility implementing Latin hypercube sampling from multivariate normal, uniform & empirical distribution. Correlation among variables can be specified. 2004. Disponível em: <<http://www.mathworks.com/matlabcentral/fileexchange/4352-latin-hypercube-sampling>>. Acesso em: 2004.
- MONTGOMERY, D. C.; RUNGER, G. C. **Estatística Aplicada e Probabilidade Para Engenheiros**. 2nd:Rio de Janeiro. 2003
- MOON, J. W.; YOON, S.-H.; KIM, S. Development of an artificial neural network model based thermal control logic for double skin envelopes in winter. **Building and Environment**, v. 61, p. 149-159. 2013.
- MOORE, F. **Concepts and practice of architectural daylighting**: New York: Van Nostrand Reinhold. 1991. 271 p.
- MOORE, T.; CARTER, D. J.; SLATER, A. A study of opinion in offices with and without user controlled lighting. **Lighting Research & Technology**, v. 36, n. 2, p. 131-146. 2004.

- MORAES, L. N.; CLARO, A. Estudo comparativo de sistemas de iluminação artificial considerando luz natural e consumo de energia. **Ambiente Construído** v. 12, p. 7-14. 2014.
- MORAES, L. N.; PEREIRA, F. O. R. **Um método simplificado para avaliação do desempenho dinâmico da iluminação natural**. In: XI Encontro Nacional de Conforto no Ambiente Construído E VII Encontro Latino Americano de Conforto no Ambiente Construído. Búzios, RJ: ANTAC, 2011.
- _____. **Desenvolvimento de um método simplificado para avaliação do desempenho dinâmico da luz natural e sua influência sobre a eficiência energética** In: III Encontro da Associação Nacional de Pesquisa e Pós-graduação em Arquitetura e Urbanismo: arquitetura, cidade e projeto - uma construção coletiva: Simpósio Temático Iluminação, qualidade e eficiência energética: contribuições ao contexto brasileiro - Coordenador: Cláudia Naves David Amorim (UnB). São Paulo: ANPARQ. 20 a 24 de outubro, 2014. 13 p.
- MORAIS, C. M. **Escalas de Medida, Estatística Descritiva e Inferência Estatística**. Bragança: Escola Superior de Educação - Instituto Politécnico de Bragança. 2005. 29 p.
- MORET, S.; NORO, M.; PAPAMICHAEL, K. **Daylight Harvesting: A Multivariate Regression Linear Model for Predicting the Impact on Lighting, Cooling and Heating**. In: Building Simulation Applications BSA 2013 - 1st IBPSA Italy regional conference on building performance simulation. Bozen-Bolzano: Bolzano University Press. 30 de janeiro a 1 de fevereiro, 2013. 39-48 p. 2013.
- MOURA, N. C. S.; *et al.* Arquitetura e desempenho luminoso: CENPES II, o novo centro de pesquisas da Petrobras, no Rio de Janeiro, Brasil. **Revista Ambiente Construído**, v.9, n.2, jan/març 2009, p.22. 2009.
- NABIL, A.; MARDALJEVIC, J. Useful daylight illuminance: a new paradigm for assessing daylight in buildings. **Lighting Research & Technology**, v.3 7, n. 1, p. 41-59. 2005.
- _____. Useful daylight illuminances: A replacement for daylight factors. **Energy and Buildings**, v. 38, n. 7, p. 905-913. 2006.
- NETO, A. H.; FIORELLI, F. A. S. Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption. **Energy and Buildings**, v. 40, n.1 2, p. 2169-2176. 2008.
- NG, E. A simplified daylighting design tool for high-density urban residential buildings. **Lighting Research and Technology** v.33, n.4, p.259-269. 2001.
- NGUYEN, A.; REITER, S.; RIGO, P. A review on simulation-based optimization methods applied to building performance analysis. **Applied Energy**, v. 113, p. 1043-1058. 2014.
- O'CONNOR, J.; *et al.* **Tips for Daylighting with Windows Report. LBNL-39945**. Lawrence Berkeley National Laboratory. USA: Berkeley. 1997. 107 p.
- OLOFSSON, T.; ANDERSSON, S.; ÖSTIN, R. A method for predicting the annual building heating demand based on limited performance data. **Energy and Buildings**, v. 28, n. 1, p. 101-108. 1998.
- PAPAMICHAEL, K.; *et al.* Product modeling for computer-aided decision-making. **Automation in Construction**, v. 8, p. 339-350. 1999.

- PAPAMICHAEL, K.; FERNANDES, L. L.; TCHANAVHAREONKIT, A. **Research Matters: HDR Imaging. LD+A: Lighting Design and Application**. Novembro de 2010. p. 26-29. 2010.
- PAPAMICHAEL, K.; LAPORTA, J.; CHAUVET, H. L. **Building Design Advisor: Automated Integration of Multiple Simulation Tools**. Lawrence Berkeley Laboratory. Berkeley: 08/1997. 1997. (LBNL-40591). 15 p.
- PAPAMICHAEL, K.; PROTZEN, P. **The Limits of Intelligence in Design**. In: Proceedings of the Focus Symposium on “Computer-Assisted Building Design Systems” of the 4th International Symposium on Systems Research, Informatics and Cybernetics. Baden-Baden, Alemanha. 3 e 4 de agosto 1993.
- PAPAMICHAEL, K.; *et al.* High Color Rendering Can Enable Better Vision without Requiring More Power. **Leukos**, mar. 2015, p. 1–12. 2015.
- PAPST, A. L. **Diretrizes Bioclimáticas para Estruturação do Programa de Necessidades**. In: XI Encontro nacional de Tecnologia do Ambiente Construído: A Construção do Futuro. Florianópolis: ANTAC. 23 a 35 de agosto, 2006. p. 729-738. 2006.
- PATTANASETHANON, S.; *et al.* An accuracy assessment of an empirical sine model, a novel sine model and an artificial neural network model for forecasting illuminance/irradiance on horizontal plane of all sky types at Mahasarakham, Thailand. **Energy Conversion and Management**, v. 49, n. 8, p. 1999-2005. 2008.
- PAULE, B.; COMPAGNON, R.; SCARTEZZINI, J. L. **Towards a new daylighting design computer-tool**. In: Proceedings of the Right-Light Three conference. Newcastle upon Tyne, 1995.
- PAULUS, M. T.; CLARIDGE, D. E.; CULP, C. Algorithm for automating the selection of a temperature dependent change point model. **Energy and Buildings**, v. 87, p. 95-104. 2015.
- PEDRINI, A.; SZOKOLAY, S. Recomendações para o desenvolvimento de uma ferramenta de suporte às primeiras decisões projetuais visando o desempenho energético de edificações de escritório em clima quente. **Revista Ambiente Construído**, v. 5, n.1, jan/març 2005. 2005. 16 p.
- PEREIRA, F. O. R. **Luminous and Thermal Performance of Shading and Sunlighting Reflecting Devices**. Building Science Unit School of Architectural Studies University Of Sheffield, University Of Sheffield, Sheffield, 1992. 301 p.
- PEREIRA, F. O. R.; CLARO, A.; SOUZA, M. B. D. **Comparação entre os sistemas automáticos de controle em resposta a luz natural em ambientes com iluminação através de janelas em paredes adjacentes**. In: Encontro Nacional de Tecnologia do Ambiente Construído. Florianópolis, SC: ANTAC, 2006. 11 p.
- PEREIRA, F. O. R.; *et al.* **Iluminação Natural: Comparação entre Percepção Visual e Medidas Dinâmicas de Avaliação**. In: XIV ENTAC - Encontro Nacional de Tecnologia do Ambiente Construído Juiz de Fora. 29 a 31 de Outubro, 2012. p. 3073 – 3081. 2012.
- _____. **An Investigation about the Consideration of Daylighting along the Design Stages**. In: Passive and Low Energy Architecture - PLEA, 2005: Environmental Sustainability - The Challenge of Awareness in Developing Societies. Beirute, 2005. p. 1025-1030 . 2005.

- _____. **Refinamento de método simplificado para avaliação do desempenho dinâmico da iluminação natural.** In: Anais do ENTAC 2012 - XIV Encontro Nacional de Tecnologia do Ambiente Construído. Juiz de Fora, MG: ANTAC. 29 a 31 de outubro, 2012.
- PEREIRA, F. O. R.; NOME, C. A. **Simulador de Trajetórias Solares - SOLARSCÓPIO.** Funpesquisa 94/95. LABCON, UFSC: CNPq 1995.
- PEREIRA, F. O. R.; PEREIRA, R. C.; GONZALES, A. C. Quão confiáveis podem ser os modelos físicos em escala reduzida para avaliar a iluminação natural em edifícios? . **Revista Ambiente Construído**, v. 12, n. 1, jan./mar., p. 131-147. 2012.
- PEREZ, R.; *et al.* Modeling daylight availability and irradiance components from direct and global irradiance. **Solar Energy**, v. 44, n. 5, p. 271-289. 1990.
- PETERS, T. N. **Daylight - Dfcalc.** This program was written to show how daylight is distributed in a room. The program, so far, only calculates the sky component daylight factor for a uniform sky.Chicago.2004. Disponível em: <<http://www.archiphysics.com/>>. Acesso em: junho de 2014.
- PETERSEN, S.; HVIID, C. A. **idbuild - Integrated design of low energy buildings.**2013b.2013. Disponível em: <<http://www.idbuild.dk/index.php/idbuild2>>. Acesso em: março de 2014
- PETRI, I.; *et al.* A modular optimisation model for reducing energy consumption in large scale building facilities. **Renewable and Sustainable Energy Reviews**, v. 38, p. 990-1002. 2014.
- PHILIPS. **Iluminação Philips para Lojas: Destaque seus produtos com tecnologia e sustentabilidade e atraia mais clientes.** Disponível em: <http://www.lighting.philips.com.br/pwc_li/main/shared/assets/downloads/Brochura_Shops_FINAL.pdf>. Acesso em maio de 2014.38p.
- _____. **Lighting for LEED: Application guide for sustainable offices.** Disponível em: <<http://www.lighting.philips.com/main/shared/assets/images/applications/office/tools-and-literature-office/leed-brochure.pdf>>. Acesso em maio de 2014. 35p.
- PIZARRO, P. R. **Estudo de variáveis do conforto térmico e luminoso em ambientes escolares.** (dissertação de mestrado). Faculdade de arquitetura, artes e comunicação, Universidade Estadual Paulista, Bauru, 2005. 179 p.
- PIZARRO, P. R.; SOUZA, L. C. L. Qualificação da iluminação natural em interiores - aplicação das redes neurais artificiais e 3DSkyView. **Revista Ambiente Construído**, v. 7, n. 1, jan/març 2007, p. 83-96. 2007.
- PRIDDLE, P.; PRIDDLE, J. **NumBerS: numerical methods for biosciences students.** The Higher Education Academy: Center of Bioscience. Anglia Ruskin University. Disponível em: <<http://web.anglia.ac.uk/numbers/index.html>>. Acesso em: março de 2014.
- QIN, R.; *et al.* Research on a dynamic simulation method of atrium thermal environment based on neural network. **Building and Environment**, v.50, p.214-220. 2012.
- QUEIPO, N. V.; *et al.* Surrogate modeling-based optimization for the integration of static and dynamic data into reservoir description. **Journal of Petroleum Science and Engineering**, v. 35, p. 167-181. 2002.

- RAKHA, T.; NASSAR, K. Genetic algorithms for ceiling form optimization in response to daylight levels. **Renewable Energy**, v. 36, n. 9, p. 2348-2356. 2011.
- RAMOS, G. **Análise da iluminação natural calculada por meio do programa Energyplus**. (dissertação de mestrado). Engenharia Civil. Universidade Federal de Santa Catarina. 2008. 111 p.
- RAMOS, G.; GHISI, E. Analysis of daylight calculated using the EnergyPlus programme. **Renewable and Sustainable Energy Reviews**. n. 14, p. 1948 - 1958. 2010.
- _____. Avaliação do cálculo da iluminação natural realizada pelo programa EnergyPlus. **Revista Ambiente Construído**, v. 10, n. 2. 2010. 10 p.
- RAPONE, G.; SARO, O. Optimisation of curtain wall façades for office buildings by means of PSO algorithm. **Energy and Buildings**, v. 45, p. 189 - 196. 2012.
- REFAEILZADEH, P.; TANG, L.; LIU, H. Cross-Validation. **Public.Asu - Arizona State University**. p.1-6. 2008.
- REINHART, C. **Daylighting Availability and Manual Lighting Control in Office Buildings - Simulation Studies and Analysis of Measurements**. Departamento de Engenharia, University of Karlsruhe, Düsseldorf, 2001. 139 p.
- _____. A simulation-based review of the ubiquitous window-head-height to daylit zone depth rule-of-thumb. **Building Simulation**. 15-18 agosto de 2005. 2005. 8 p.
- _____. **Tutorial on the Use of Daysim Simulations for Sustainable Design**: Institute for research in Construction National Research Council Canada. 2006. 114 p.
- _____. **DAYSIM: Advanced Daylighting Simulation Software**. v. 3.1e. Daysim é um programa de análise de iluminação natural validado baseado no Radiance que faz simulações anuais de ambientes internos e externos. 2 012
- REINHART, C.; *et al.* **DAYLIGHT1-2-3 - A State-Of-The-Art Daylighting/Energy Analysis Software for Initial Design Investigations**. In: Proceedings: BS2007 10th International Building Performance Simulation Association (IBPSA) Conference. Beijing. 2007. p. 1669-1676. 2007.
- REINHART, C.; FITZ, A. Findings from a survey on the current use of daylight simulations in building design. **Energy and Buildings**, v. 38, n.7 , p.8 24-835. 2006.
- REINHART, C.; MORRISON, M. **The lightswitch wizard – reliable daylight simulations for initial design investigation**. In: Building Simulation. Eindhoven, The Netherlands, 2003. p. 1093-1100. 2003.
- REINHART, C.; PIERRE-FELIX, B. Experimental validation of Autodesk® 3ds Max® design 2009 and Daysim 3.0. **LEUKOS - Journal of Illuminating Engineering Society of North America**, v. 6, n.1, p. 7-35. 2009.
- REINHART, C.; RAKHA, T.; WEISSMAN, D. Predicting the Daylit Area—A Comparison of Students Assessments and Simulations at Eleven Schools of Architecture. **LEUKOS - Journal of Illuminating Engineering Society of North America**, v. 10, n. 4, p.193-206. 2014.
- REINHART, C. F. Lightswitch-2002: a model for manual and automated control of electric lighting and blinds. **Solar Energy**, v. 77, n. 1, p. 15-28. 2004.
- REINHART, C. F.; ANDERSEN, M. Development and validation of a Radiance model for a translucent panel. **Energy and Buildings**, v. 38, n. 7, p. 890-904. 2006.

- REINHART, C. F.; HERKEL, S. The simulation of annual daylight illuminance distributions -- a state-of-the-art comparison of six RADIANCE-based methods. **Energy and Buildings**, v. 32, n. 2, p. 167-187. 2000.
- REINHART, C. F.; LOVERSO, V. R. M. A rules of thumb-based design sequence for diffuse daylight. **Lighting Research & Technology**, v. 42, n. 1, p. 7-31. 2007.
- _____. A rules of thumb-based design sequence for diffuse daylight. **Lighting Research & Technology**, v. 42, n. 1, p. 7-31. 2010.
- REINHART, C. F.; MARDALJEVIC, J.; ROGERS, Z. Dynamic daylight performance metrics for sustainable building design. **LEUKOS - Journal of Illuminating Engineering Society of North America**, v. 3, n. 1, p. 7-31. 2006.
- REINHART, C. F.; WALKENHORST, O. Validation of dynamic RADIANCE-based daylight simulations for a test office with external blinds. **Energy and Buildings**, v. 33, n. 7, p.683-697. 2001.
- REINHART, C. F.; WIENOLD, J. The daylighting dashboard - A simulation-based design analysis for daylit spaces. **Building and Environment**, v. 46, n. 2, p. 386-396. 2011.
- REPPERT, S. M.; WEAVER, D. R. Coordination of circadian timing in mammals. **Nature**, v. 418, n. 6901, 29 de agosto, p.935-941. 2002.
- RISSO, V. F.; RISSO, F. V. A.; SCHIOZER, D. J. **Aplicação da técnica do hipercubo latino no treinamento de redes neurais na análise de risco de campos de petróleo. Rio Oil and Gas Expo and Conference 2010.** Rio de Janeiro/Brasil: Rio Oil and Gas Expo and Conference 2010.
- ROCHA, A. P. A.; PEREIRA, F. O. R. **Zoneamento da iluminação natural para melhorar o desempenho energético dos sistemas de controle de iluminação ligados à luz natural em ambientes de escritório. Conferência Internacional REGSA 2014: Energias Renováveis, Eficiência Energética e Desenvolvimento Sustentável.** Florianópolis: REGSA -UNISUL, 2014.
- RODRIGUES, T. B.; MACRINI, J. L. R.; MONTEIRO, E. C. Seleção de variáveis e classificação de padrões por redes neurais como auxílio ao diagnóstico de cardiopatia isquêmica. **Pesquisa Operacional**, v. 28, n. 2, maio/agosto. 2008.
- ROGERS, Z. **Daylighting Metric Development Using Daylight Autonomy Calculations In the Sensor Placement Optimization Tool - Development Report and Case Studies.** Architectural Energy Corporation. Boulder/ Colorado: 17 de março de 2006. 2006. 52 p.
- ROLDÁN-BLAY, C.; *et al.* Upgrade of an artificial neural network prediction method for electrical consumption forecasting using an hourly temperature curve model. **Energy and Buildings**, v. 60, p. 38-46. 2013.
- ROSIEK, S.; BATLLES, F. J. Performance study of solar-assisted air-conditioning system provided with storage tanks using artificial neural networks. **International Journal of Refrigeration**, v. 34, n. 6, p. 1446-1454. 2011.
- ROTMANS, J.; VRIEZE, O. J. Metamodelling and experimental design: Case study of the greenhouse effect **European Journal of Operational Research**, v.4 7, p. 317-329 1990.

- ROY, J. SR, **Shadow and Reflection Analysis, A system for IBM compatible PCs for modelling the built environment and the computation and display of shadows and reflection caused by sunlight.** Murdoch. 1995
- RUBINSTEIN, F.; ENSCOE, A. Saving energy with highly-controlled lighting in an open-plan office. **LEUKOS - Journal of Illuminating Engineering Society of North America**, v. 7, n. 1, p. 21-36. 2010.
- RUGGIERO, F.; FLORENSA, R. S.; DIMUNDO, A. Re-interpretation of traditional architecture for visual comfort. **Building and Environment**, v. 44, n. 9, p. 1886-1891. 2009.
- RUPP, R.; GHISI, E. **Daylighting Performance and Potential for Electricity Savings by Using Daylighting in Commercial Buildings Located in Florianópolis, Brazil.** In: Proceedings of The Second International Conference on Building Energy and Environment. Boulder: COBEE - International Conference on Building Energy and Environment. 1 - 4 de agosto, 2012. 6 p.
- RUPP, R.; GHISI, E. **Sizing Window Areas for Daylighting and Hybrid Ventilation in Commercial Buildings.** In: Proceedings of PLEA2012 - 28th Conference, Opportunities, Limits & Needs Towards an environmentally responsible architecture. Lima: PLEA - Passive and Low Energy Architecture. 1 - 9 de novembro, 2012. 8 p.
- RUTTEN, D. **Evolutionary Principles Applied to Problem Solving** Disponível em: David Rutten's blog < <http://ieatbugsforbreakfast.wordpress.com/2011/03/04/epatps01/>>. Acesso em: 15 de julho de 2014.
- SANTANA, M. **A influência de parâmetros construtivos no consumo de energia de edifícios de escritórios localizados em Florianópolis.** Engenharia Civil, Universidade Federal de Santa Catarina, Florianópolis, 2006. 181 p.
- SAXENA, M. Windows Are For People: Where Do Daylight and Views Fit In the Window Energy Equation? **Journal of the National Institute of Building Sciences**, v. 1, n. 2, agosto de 2013, p.1 0-12. 2013.
- _____. **The New IES-Approved Daylight Metrics.** IBPSA. Disponível em: <<http://www.ibpsa.com/category/webinars/>> e <<http://daylightmetrics.blogspot.com.br/2014/10/the-new-ies-approved-daylight-metrics.html>>. Acesso em: 23 de outubro de 2014.
- SAXENA, M., *et al.* **61 Flavors of daylight.** In: Proceedings of the ACEEE Summer Study 2010 on Energy Efficiency in Buildings. Asilomar: Washington (DC): American Council for an Energy-Efficient Economy, 2010. p. 238 – 361. 2010.
- SCHUETTER, S. **Back of the Envelope Calculator.** Shows real-time energy connections between building components, isolate the effects of changing a single energy parameter, or produce concept-level energy and CO2 emissions estimates. Madison. 2010. Disponível em: < <http://www.ecw.org/boecalc> >. Acesso em: março de 2014.
- SELKOWITZ, S.; GABEL, M. **LBL Daylighting Nomographs.** Lawrence Berkeley Laboratory. Berkeley. 1984. (LBL-13534)
- SELKOWITZ, S.; *et al.* **The DOE-2 and SUPERLITE Daylighting Programs.** In: PASSIVE'82: The National Passive Solar Conference. Knoxville. 29 de agosto a 3 de setembro, 1982. 6 p.

- SELLITTO, M. A. Processos de Pensamento da Toc como Alternativa Sistêmica de Análise Organizacional: Uma Aplicação dm Saúde Pública. **Gestão e Produção**, v. 12, n. 1, janeiro/abril, p. 81-96. 2005.
- SHAN, R. Optimization for Heating, Cooling and Lighting Load in Building Façade Design. **Energy Procedia**, v. 57, p. 1716-1725. 2014.
- SHEN, E.; HU, J.; PATEL, M. Energy and visual comfort analysis of lighting and daylight control strategies. **Building and Environment**, v. 78, p. 155-170. 2014.
- SHEN, H.; TZEMPELIKOS, A. **Sensitivity Analysis on Daylighting and Energy Performance of Perimeter Office Spaces**. In: 2nd International High Performance Buildings Conference at Purdue. Lafayette: Purdue e-Pubs. 16 a 19 de julho de 2012. Artigo 67, 10 p.
- SIGNOR, R. **Análise de regressão do consumo de energia elétrica frente a variáveis arquitetônicas para edifícios comerciais climatizados em 14 capitais brasileiras**. (dissertação de mestrado). Departamento de Engenharia Civil, UFSC, Florianópolis, 1999. 122 p.
- SILVA, A. N. R. D.; *et al.* **SIG: Uma plataforma para introdução de técnicas emergentes no planejamento urbano, regional e de transportes - Uma ferramenta 3D para análise ambiental urbana, avaliação multicritério e redes neurais artificiais**. 1: São Paulo: Ed. dos Autores. 2004. 227 p.
- SILVA, A. P. **Separação Cega de Misturas Convolutivas no Domínio do Tempo Utilizando Clusterização**. (monografia). Departamento de Eletrônica e de Computação, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2009. 53 p.
- SILVA, A. S.; GHISI, E. Análise comparativa dos resultados do desempenho térmico da envoltória de uma edificação residencial pelos métodos de simulação do RTQ-R e da NBR 15575-1 **Revista Ambiente Construído**, v. 14, n. 1, jan./ mar., p. 213-230. 2012.
- SILVA, R. M. **Redes Neurais Artificiais aplicadas à Detecção de Intrusão em Redes TCP/IP** Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2005. 144 p.
- SILVA, R. M.; ALMEIDA, T. A.; YAMAKAMI, A. Análise de desempenho de redes neurais artificiais para classificação automática de web spam. **Revista Brasileira de Computação Aplicada**, v. 4, n. 2, outubro, p. 42-57. 2012.
- SOLEMMMA LLC. **DIVA for Rhino: Environmental Analysis for Buildings**. v. 2.0. DIVA-for-Rhino é um *plug-in* de modelagem de iluminação natural e energia altamente otimizado para o modelador Rhinoceros - NURBS. 2014. Disponível em: <<http://diva4rhino.com/>>. Acesso em: setembro de 2013.
- SOUZA, M. B. D. **Potencialidade de aproveitamento da luz natural através da utilização de sistemas automáticos de control para a economia de energia elétrica**. Engenharia Civil, Universidade Federal de Santa Catarina, Florianópolis, 2003. 208 p.
- SOUZA, R. V. G. **Desenvolvimento de Modelos Matemáticos Empíricos para a Descrição dos Fenômenos de Iluminação Natural Externa e Interna**. (tese). Departamento de Engenharia Civil, Universidade Federal de Santa Catarina, Florianópolis, 2004. 293 p.

- STEVANOVIC, S. Optimization of passive solar design strategies: A review. **Renewable and Sustainable Energy Reviews**, v. 25, p. 177-196. 2013.
- SUCUPIRA, I. R. **Métodos heurísticos genéricos: meta-heurísticas e hiper-heurísticas**. (monografia). Departamento de Ciências da Computação, Universidade de São Paulo, São Paulo, 2004. 41 p.
- SUMATHI, S.; PANEERSELVAM, S. **Computational Intelligence Paradigms -Theory and applications using Matlab**. New York: Tylor and Franscis Group: 2010. 821 p.
- SZERMAN, M. Daylighting in adjacent rooms connected to an atrium by artificial sky measurements. **Building Research and Information** v. 20, n. 6, p. 357-359. 1992.
- T.R.C-H.M.G. **SkyCalc™**. Energy Design Resources. 2009
- _____. **Skylighting Design Guidelines: energy design resources**. California Public Utilities Commission, 2014. 133 p.
- THE MATHWORKS INC. **MatLab** 2011a. Linguagem computacional técnica. Natick. 2011a. Disponível em: <<http://www.mathworks.com/products/neuralnet/description1.html>>. Acesso em: 25 de junho de 2011.
- _____. **MatLab - Neural Network Toolbox**. 2011a. Linguagem computacional técnica. Natick. 2011b. Disponível em: <<http://www.mathworks.com/products/neuralnet/description1.html>> .Acesso em: 25 de junho de 2011.
- _____. **MATLAB CENTRAL: File Exchange** Disponível: <<http://www.mathworks.com/matlabcentral/fileexchange>>. Acesso em: 4 de junho de 2014.
- _____. **MATLAB Documentation**. Natick: The Mathworks Inc. 2014.
- THIRUGNANASAMBANDAM, M., INIYAN, S. e GOIC, R. A review of solar thermal technologies. **Renewable and Sustainable Energy Reviews**, v. 14, n. 1, p. 312-322. 2010.
- TÍBA, C.; LEAL, S. S. Measuring and modelling illuminance in the semi-arid Northeast of Brazil. **Renewable Energy**, v. 48, p. 464-472. 2012.
- TILLER, D.; *et al.* Validating the application of occupancy sensor networks for lighting control. **Lighting Research and Technology**, v. 42, 21 de Maio de 2010, p.399-414. 2010.
- TOMAZIC, S.; *et al.* Indoor-environment simulator for control design purposes. **Building and Environment**, v. 70, p. 60-72. 2013.
- TONNE, F. **HORIZONTOSCOPE: The tool is still distributed by the Institut für Tageslichttechnik, Eichgehrenweg 3** Institut für Tageslichttechnik Stuttgart. Disponível em: <http://www.horizontoscop.com/eng/index_eng.html>. Acesso em: março de 2014.
- TREGUENZA, P. R.; WATERS, I. M. Daylight coefficient. **Lighting, Research and Technology**, v. 15, jun. 1983, p. 6. 1983.
- TRIPP, D. Pesquisa-ação: uma introdução metodológica. **Educação e Pesquisa**, v. 31, n. 3, setembro/dezembro, p. 443-466. 2005.

- TROBEC LAH, M.; *et al.* Daylight illuminance control with fuzzy logic. **Solar Energy**, v. 80, n. 3, p. 307-321. 2006.
- TUHUS-DUBROW, D.; KRARTI, M. Genetic-algorithm based approach to optimize building envelope design for residential buildings. **Building and Environment**, v. 45, n. 7, p. 1574-1581. 2010.
- TURRIN, M.; VON BUELOW, P.; STOUFFS, R. Design explorations of performance driven geometry in architectural design using parametric modeling and genetic algorithms. **Advanced Engineering Informatics**, v. 25, n. 4, p. 656-675. 2011.
- UPADHYAYA, B. R.; EVREN, E. Application of Neural Networks for Sensor Validation and Plant Monitoring. **Nuclear Technology**, v. 97, p. 170-176. 1992.
- US DEPARTMENT OF ENERGY - US-DOE. **EnergyPlus Energy Simulation Software - Weather Data** Disponível em: <http://apps1.eere.energy.gov/buildings/energyplus/weatherdata_about.cfm>. Acesso em: fevereiro de 2013.
- _____. **Annual energy outlook** Disponível em: <<http://www.eia.gov/forecasts/aeo/er/?src=Consumption-f1>>. Acesso em: 05 de maio de 2014.
- _____. **Building Energy Software Tools Directory** Disponível em: <http://apps1.eere.energy.gov/buildings/tools_directory/>. Acesso em: 25 de janeiro de 2015.
- U.S. Green Building Council - USGBC, **Green Building Design and Construction**. Washington: USGBC: 2009. 647 p.
- VELUX. **VELUX Daylight Visualizer**. It is a professional and accessible tool for simulating daylight levels in buildings. Its simple interface allows both the novice and experienced user to set up and simulate daylight in building models.2013. Disponível em: <<http://viz.velux.com/>>. Acesso em: março de 2014.
- VENÂNCIO, R.; PEDRINI, A. **The influence of design decisions on energy consumption and thermal performance: the case of UFRN Campus, Brazil. Building Simulation - Eleventh International IBPSA Conference**. Glasgow/Scotland: IBPSA 2009.
- VERSAGE, R.; MELO, A. P.; LAMBERTS, R. **Impact of different daylighting simulation results on the prediction of total energy consumption. SimBuild 2010 - Fourth National Conference of IBPSA-USA**. New York: IBPSA 2010.
- VIANNA, A. C. F. **Things you wanted to know about the Latin hypercube design and were afraid to ask**. In: 10th World Congress on Structural and Multidisciplinary Optimization. Florida. 19 a 24 de setembro, 2013. 9 p.
- VICENTE, R. **Redes Neurais para Inferência Estatística**. FEA/USP- Universidade de São Paulo. São Paulo: junho 2002. 2002. 647 p.
- WALCH, J. M.; *et al.* The effect of sunlight on postoperative analgesic medication use: A prospective study of patients undergoing spinal surgery. **Psychosomatic Medicine**, v. 67, n. 1, janeiro/fevereiro, p. 156-163. 2005.
- WALDRAM, P. J. **A Measuring Diagram for Daylight Illumination**: London: B.T. Batsford Ltd. 1950

- WANG, W.; ZMEUREANU, R.; RIVARD, H. Applying multi-objective genetic algorithms in green building design optimization. **Building and Environment**, v. 40, n. 11, p. 1512-1525. 2005.
- WARD, G. J. **The RADIANCE Lighting Simulation and Rendering System**. In: Computer Graphics - SIGGRAPH conference. Orlando/Flórida. Jul. 1994. p. 459-72, 1994.
- WEISSTEIN, E. W. **Kolmogorov-Smirnov Test**. From MathWorld - A Wolfram Web Resource. Disponível em: <<http://mathworld.wolfram.com/Kolmogorov-SmirnovTest.html>>. Acesso em janeiro de 2014.
- WESTPHAL, F. S. **Análise de incertezas e de sensibilidade aplicadas à simulação de desempenho energético de edificações comerciais**. Programa de Pós Graduação em Engenharia Civil, Universidade Federal de Santa Catarina, Florianópolis, 2007. 131 p.
- _____. **Macro Excel Visual Basic para parametrização de modelos para o EnergyPlus**. Florianópolis.2012
- WESTPHAL, F. S.; LAMBERTS, R. **Regression analysis of electric energy consumption of commercial buildings in Brazil**. In: Proceedings of Building Simulation. Beijing. 3 a 6 de setembro, 2007. p. 1543-1550, 2007.
- WILLIAMS, A.; *et al.* Lighting Controls in Commercial Buildings. **LEUKOS - Journal of Illuminating Engineering Society of North America**, v. 8, n. 3, p. 161 a 180. 2012.
- WINKELMANN, F. C.; SELKOWITZ, S. Daylighting simulation in the DOE-2 building energy analysis program. **Energy and Buildings**, v. 8, n. 4, p. 271-286. 1985.
- WOLSTENHOLME, S. **Doubts about hidden layer (EasyNNplus)** Mensagem recebida por: <raphawf@gmail.com> em 28 de maio de 2013.
- _____. **EasyNNplus.v.1.6**. Programa de interface amigável para elaboração de redes neurais artificiais.2013b
- _____. **EasyNNplus: user interface manual**<http://www.easynn.com/108491/EasyNN-plus.pdf>.
- WONG, S. L.; WAN, K. K. W.; LAM, T. N. T. Artificial neural networks for energy analysis of office buildings with daylighting. **Applied Energy**, v. 87, n. 2, p. 551-557. 2010.
- WRIGHT, J. A.; LOOSEMORE, H. A.; FARMANI, R. Optimization of building thermal design and control by multi-criterion genetic algorithm. **Energy and Buildings**, v. 34, n. 9, p. 59-972. 2002.
- YAHIAOUI, G.; DA SILVA DIAS, P. **NEXYAD: What is a mathematical model?** © NEXYAD Disponível em: < <http://www.nexyad.net/HTML/e-book-Matematical-Model.html> >. Acesso em: setembro de 2014.
- YANG, J.; RIVARD, H.; ZMEUREANU, R. On-line building energy prediction using adaptive artificial neural networks. **Energy and Buildings**, v. 37, n. 12, p.1 250-1259. 2005.
- YANG, X.-S.; ASADI, S.; GEEM, Z. Sustainable Building Design: A Review on Recent Metaheuristic Methods. In: (Ed.). **Recent Advances in Swarm Intelligence and Evolutionary Computation**: Springer International Publishing, v. 585, 2014. Sustainable Building Design: A Review on Recent Metaheuristic Methods, p.203-223. (Studies in Computational Intelligence). 2014.

- YEZIORO, A.; DONG, B.; LEITE, F. An applied artificial intelligence approach towards assessing building performance simulation tools. **Energy and Buildings**, v. 40, n. 4, p. 612-620. 2008.
- YOON, Y. B.; JEONG, W. R.; LEE, K. H. Window Material Daylighting Performance Assessment Algorithm: Comparing Radiosity and Split-Flux Methods **Energies** 2, v. 7, p. 2362-2376. 2014.
- YOUNG, S. N. How to increase serotonin in the human brain without drugs. **Journal of Psychiatry & Neuroscience**, v.3 2, n. 6, p. 394-399. 2007.
- YU, W.; *et al.* Application of multi-objective genetic algorithm to optimize energy efficiency and thermal comfort in building design. **Energy and Buildings**, v. 88, p. 135-143. 2015.
- YUN, G.; KIM, K. S. An empirical validation of lighting energy consumption using the integrated simulation method. **Energy and Buildings**, v. 57, p. 144–154. 2013.
- ZAMORA-MARTÍNEZ, F.; *et al.* On-line learning of indoor temperature forecasting models towards energy efficiency. **Energy and Buildings**, v. 83, p. 162-172. 2014.
- ZEMELLA, G.; *et al.* Optimised design of energy efficient building façades via Evolutionary Neural Networks. **Energy and Buildings**, v. 43, n. 12, p. 3297-3302. 2011.
- ZERPA, L. E.; *et al.* An optimization methodology of alkaline-surfactant-polymer flooding process using field scale numerical simulation and multiple surrogates. **Journal of Petroleum Science and Engineering**, v. 47, p. 197-2008. 2005.
- ZHANG, Y.; *et al.* Comparisons of inverse modeling approaches for predicting building energy performance. *Building and Environment*, v. 86, p. 177-190. 2015.
- ZHAO, H.-X.; MAGOULÈS, F. A review on the prediction of building energy consumption. *Renewable and Sustainable Energy Reviews*, v. 16, n. 6, p. 3586-3592. 2012.
- ZMEUREANU, R. Prediction of the cop of existing rooftop units using artificial neural networks and minimum number of sensors. *Energy*, v. 27, n. 9, p. 889-904. 2002.

GLOSSÁRIO

Amostragem por Hiper-cubo Latino	– é um método de amostragem baseado no método de Monte Carlo no qual, apesar de os sorteios também serem aleatórios, esses se dão dentro as faixas previamente definidas.
Abertura de iluminação natural ou abertura efetiva	– é o produto entre o percentual de abertura da fachada e a transmissão visível do vidro (<i>daylight aperture or effective aperture</i>).
Abertura Solar	– é o produto entre o percentual de abertura da fachada e o coeficiente de sombreamento (<i>solar aperture</i>).
Arquitetura da rede neural	– forma como os neurônios que compõem a rede se agrupam incluindo a sua disposição e o direcionamento das conexões sinápticas.
Clusterização	– termo adaptado do inglês para definir um agrupamento de coisas ou atividades semelhantes que funcionam analogamente.
Épocas	– quantidade de interações para o treinamento de uma RNA.
Heurísticas	– termo utilizado na área de Ciências da Computação empregado para métodos ou algoritmos que resultam em soluções sem um limite formal de qualidade, normalmente avaliado empiricamente (SUCUPIRA, 2004).
Padrões	– Segundo Babini (2006): <div style="padding-left: 40px;">unidades de informação que se repetem ou sequência de informações que possuem uma estrutura que se repete.</div> Neste trabalho os padrões são os exemplos das variáveis-chave/parâmetros.

Parâmetros – neste trabalho são chamados de parâmetros as variáveis-chave da iluminação natural/desempenho luminoso e termoenergético que são utilizadas como padrões de entrada e saída para o treinamento das RNAs.

Variável – neste trabalho o termo “variável” é associado às variáveis-chave da iluminação natural/desempenho luminoso e termoenergético e pode ser utilizado como sinônimo de “parâmetro” e “padrões”, visto que foram usadas em combinações paramétricas e como padrões de entrada e saída para RNAs.

APÊNDICE

APÊNDICE A – COMPILAÇÃO E ANÁLISE DO LEVANTAMENTO BIBLIOGRÁFICO SOBRE FERRAMENTAS SIMPLIFICADAS PARA ESTIMATIVA DE ILUMINAÇÃO NATURAL

A compilação e análise bibliográfica aqui propostas foram desenvolvidas a partir da pesquisa sobre ferramentas simplificadas desenvolvida pela IEA (2000) no contexto da TASK 21 – Subtask C: Daylighting Design Tools. Como apresentado no item 2.2 da revisão bibliográfica, a referida pesquisa classificou as ferramentas simplificadas em oito categorias: I. Fórmulas empíricas, II. Tabelas, III. Nomogramas, IV. Diagramas, V. Transferidores, VI. Aplicativos computacionais, VII. Tipologias e VIII. Modelos em escala (numeração de acordo com o Quadro 5) (DE BOER; ERHORN, 1999). Diante dos estudos encontrados durante a revisão de literatura, incluiu-se uma nova categoria: IX. Ferramentas estatísticas/computacionais.

Mantendo-se a classificação apresentada pela pesquisa da TASK 21, buscou-se atualizar a listagem de ferramentas incluindo novas ferramentas divulgadas na literatura e avaliadas segundo critérios apresentados no Quadro 3 e na Figura 131. Para tal, sintetizaram-se as informações levantadas de acordo com uma hierarquia (ver Quadro 4) que elencou a principal limitação dos métodos segundo a ótica deste trabalho. Assim, foi proposto um quadro, o Quadro 5, baseado na Tabela 6.1 da TASK 21 (IEA, 2000), que exibe um panorama do estado da arte de ferramentas simplificadas as quais tem a iluminação natural como foco. O quadro proposto apresenta o nome da ferramenta ou dos autores separados por categoria de acordo com a tabela-base, o objetivo principal da ferramenta (também segundo a mesma tabela) e a principal limitação inerente à concepção da ferramenta, de acordo com o Quadro 4. A descrição das limitações foi feita com base nos objetivos desta tese, não sendo indicativa de que o método não seja adequado para outros fins. É importante mencionar que a intenção desta revisão não é levantar todos os estudos existentes, mas sim discutir a abrangência e as limitações dos métodos simplificados mais difundidos na literatura.






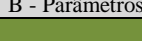






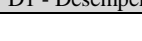



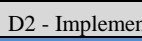


Os métodos simplificados para avaliação da iluminação natural normalmente se fundamentam em apenas uma ou na combinação das ferramentas das categorias listadas. Dessa forma, as ferramentas

selecionadas para compor o Quadro 5 foram elencadas baseando-se na sua difusão e aceitabilidade no objetivo principal de avaliação, na sua disponibilidade e conceito de concepção. Todas as ferramentas descritas têm como objetivo pelo menos um dos três tópicos a seguir: projeto de aberturas (dimensões mínimas para obter determinadas características de iluminação), zoneamento de iluminação natural e impacto da iluminação natural no desempenho energético da edificação.

Para a definição das limitações dos métodos, foi feita uma filtragem em duas etapas: na primeira, avaliaram-se os métodos de acordo com os critérios de A a D, apresentados no Quadro 3. A Figura 131 mostra como exemplo a avaliação da IX. Ferramenta Estatística – IX.5 do Quadro 5 na primeira etapa de avaliação. Na segunda etapa, para simplificação da exibição e análise geral dos métodos, elaborou-se uma lista hierárquica de requisitos. Assim, a célula de limitação do método do Quadro 5 apresenta a principal limitação do método segundo o que se buscava neste trabalho.

Esta avaliação permitiu a verificação da lacuna existente na bibliografia e a definição da contribuição deste trabalho, conforme descrito no item 2.2 da revisão bibliográfica.

Quadro 3 – Critérios utilizados para a análise dos métodos simplificados

O que se buscou nas ferramentas:	
A - Representação do fenômeno da luz e, quando aplicável, do fenômeno térmico:	
	1- considera no mínimo CC _{difusa} , CRE, CRI;
	2- considera as condições dinâmicas do céu (baseado em arquivo climático, medições ou combinação de tipos de céus);
	3- modelagem da iluminação natural pelo método do Fluxo Dividido (quando baseado no DOE-2);
	4- modelagem da iluminação natural pelo método da Radiosidade (quando baseado no SUPERLITE);
	5- modelagem da iluminação natural pelo método do Raio Traçado (quando baseado no Radiance-Rd);
	6- modela o balanço térmico completo por zona térmica;
B - Parâmetros do edifício:	
	7- sensibilidade a diferentes orientações;
	8- avalia a influência de proteções solares;
	9- considera a geometria do ambiente;
	10- avalia diferentes tipos de vidro (FS e TVIS);
	11- avalia diferentes refletâncias das superfícies;
C - Contexto do edifício:	
	12- avalia a influência do entorno;
	13- proposto para qualquer localidade (considerados em seu estado atual, modelos propostos para determinada localidade não estão incluídos, mesmo que replicáveis);
D1 - Desempenho do edifício:	
	14- resultados baseados no FLD;
	15- resultados baseados em iluminâncias;
	16- análises em séries temporais (medidas dinâmicas de iluminação);
	17- permite obtenção de medida em um ponto ou malha de pontos;
	18- resultados de consumo energético baseados em cinco zonas térmicas agrupadas com aberturas distribuídas em todas as fachadas;
D2 - Implementação:	
	19- Independente de conexão com a internet.

Fonte: Autor.

Figura 131 – Exemplo da análise dos métodos simplificados segundo os critérios exibidos no Quadro 3

(continua)	
Legenda a) Iluminação em ambientes por aberturas laterais b) Iluminação em ambientes por aberturas laterais e zenitais c) Projeto de janelas d) Projeto de zenitais e) Projeto de átrios	f) Comportamento energético/Autonomia da luz natural g) Comportamento energético/Considerando a influência nos sistemas de iluminação e condicionamento de ar h) Custo benefício do partido do aproveitamento da luz natural i) Análise de Sombras e reflexões/duração da luz do sol j) Conforto visual k) Zoneamento de iluminação natural/profundidade do ambiente para iluminação uniforme

(continua)																	
Tipo	Nº	APLICAÇÕES (Autor/Fonte)	Foco principal da ferramenta								Critérios						
			a	b	c		d	e	f	g	h	A	B	C	D		
	• •																
IX. Ferramentas estatísticas/computacionais ...	IX.5	Consumo Energético considerando o aproveitamento da Iluminação Natural (DIDONÉ; PEREIRA, 2010).							■								
	• • •																

Exemplo de um caso em que todas as células estivessem preenchidas.			
A	B	C	D

Fonte: Autor.

Quadro 4 – Hierarquia de características dos métodos simplificados consideradas como limitação

baseado no FLD;
apenas iluminação estática;
implicação apenas no sistema de iluminação artificial;
utiliza o método do Fluxo Dividido/Doe-2 ou Radiosidade/Superlite;
balanço térmico ou modelos fotométricos simplificados;
não considera ou agrupa o efeito da orientação;
não avalia diferentes propriedades do vidro (FS e T_{VIS});
não avalia diferentes geometrias;
não avalia refletâncias das superfícies;
não avalia proteções solares;
não avalia influência do entorno;
em seu estado atual aplicável a uma localidade específica;
aplicável a diretrizes de projeto;
necessita de simulação computacional simplificada.

Fonte: Autor.

Quadro 5 – Classificação dos métodos simplificados levantados na bibliografia para a verificação da iluminação natural

													(continua)
Legenda		f) Comportamento energético/Autonomia da luz natural											
a) Iluminação em ambientes por aberturas laterais		g) Comportamento energético/Considerando a influência nos sistemas de iluminação e condicionamento de ar											
b) Iluminação em ambientes por aberturas laterais e zenitais		h) Custo benefício do partido do aproveitamento da luz natural											
c) Projeto de janelas		i) Análise de Sombras e reflexões/duração da luz do sol											
d) Projeto de zenitais		j) Conforto visual											
e) Projeto de átrios		k) Zoneamento de iluminação natural/profundidade do ambiente para iluminação uniforme											
Tipo	Nº	Foco principal											Limitação
		Aplicações (Autor/Fonte)											
		a	b	c	d	e	f	g	h	i	j	k	
I. Fórmulas empíricas	I.1	CIBSE (LYNES, 1979; CIBSE, 1999) – Uma sequência para projeto de iluminação natural (Projeto de aberturas).											baseado no FLD
	I.2	Economia de energia do sistema de iluminação artificial baseado em iluminação natural (LYNES; LITTLEFAIR, 1990).											implicação apenas no sistema de ilum. artificial
	I.3	Economia anual de energia pela luz natural (W/sf)-fórmulas e tabelas (MOORE, 1991) capítulo 17, p. 206 do livro original.											baseado no FLD
	I.4	Modelos Matemáticos Empíricos para cálculo da iluminação em um ponto (SOUZA, 2004).											iluminação estática
	I.5	Dimensões de Zenitais – DIN 5034-Parte 6 (GERMAN INDUSTRIAL STANDARD, 2007a) substituição para (GERMAN INDUSTRIAL STANDARD, 1996).											baseado no FLD
	I.6	FLD, Componente refletida interna DIN 5034-Parte 3 (GERMAN INDUSTRIAL STANDARD, 2007b) substituição para (GERMAN INDUSTRIAL STANDARD, 1994a).											baseado no FLD
	I.7	Fator de abertura ($150 < TVIS \times PAP < 0,180$) (USGBC, 2009).											implicação apenas no sistema de ilum. artificial
	I.8	Sequência de projeto para Iluminação natural lateral difusa (REINHART; LOVERSO, 2010).											baseado no FLD
	I.9	Sequência de projeto para Iluminação natural zenital difusa (LOVERSO; REINHART, 2010).											baseado no FLD
	I.10	Abertura efetiva – TITLE 24 (CALIFORNIA ENERGY COMMISSION, 2013). $AE1 = (\Sigma AABERTURA \times TVIS)/AZ1$ e $AE2 = (\Sigma AABERTURA \times TVIS)/(AZ1 + AZ2)$											não considera ou agrupa o efeito da orientação
	I.11	Regra Prática: $1,5-2,5 \times$ Altura da verga=área iluminada naturalmente a partir de aberturas (ASHRAE, 2013; REINHART, 2005; USGBC, 2009).											não considera ou agrupa o efeito da orientação

Quadro 5 – Classificação dos métodos simplificados levantados na bibliografia para a verificação da iluminação natural

													(continua)	
Tipo	Nº	Foco principal Aplicações (Autor/Fonte)	Limitação											
			a	b	c	d	e	f	g	h	i	j	k	
IV. Diagramas/ Gráficos	IV.1	Alcance horizontal: duração da luz do sol (TONNE, 1950).	■	■	■	■		■				■	■	baseado no FLD
	IV.2	Diagrama de Waldran, Componente celeste direta. (WALDRAM, 1950).	■		■									baseado no FLD
	IV.3	Autonomia da luz natural: Swiss Norm SN 418911 – CH8008 (ASE, 1989).						■						baseado no FLD
	IV.4	Método dos lúmens para aberturas zenitais – I.E.S. (1979) (MOORE, 1991) Diagramas e equações.		■		■								iluminação estática
	IV.5	Horas de acionamento de iluminação (SZERMAN, 1992).						■						baseado no FLD
	IV.6	Nível de iluminação nas áreas adjacentes a átrios: HxL do átrio (átrios lineares) (ASCHEHOUG, 1992 apud BROWN; DEKAY, 2004 p.129).	■				■							iluminação estática
	IV.7	Nível de iluminação nas áreas adjacentes a átrios: Relação HxL do átrio (átrios internos) (BROWN; DEKAY, 2004).	■				■							propriedades do vidro (FS e T _{vis})
	IV.8	Profundidade do recinto (BROWN; DEKAY, 2004).											■	propriedades do vidro (FS e T _{vis})
	IV.9	Poços de luz de Claraboia (BROWN; DEKAY, 2004).					■							implicação apenas no sistema de ilum. artificial
	IV.10	Matriz de Interações para programa de necessidades de projeto: Aspectos Bioclimáticos (PAPST, 2006).			■	■	■							diretrizes de projeto
	IV.11	Diagrama da Contribuição da Iluminação Natural (ABNT, 2007).	■											iluminação estática
V. Transferidores	V.1	B. R. S. Transferidores de iluminação natural (COMMISSION OF THE EUROPEAN COMMUNITIES, 1993; DUFTON, 1940, 1946; LONGMORE, 1968).	■	■	■	■							iluminação estática	
VI. Aplicativos computacionais (simulações simplificadas ou ferramenta que remete a resultados pré- simulados) - continua	VI.1	Cálculos de iluminação natural para espaços tipo caixa de sapatos – LBL e FIBP – ADELIN (ERHORN; STOFFEL, 1996; HITCHCOCK; OSTERHAUS, 1993).	■	■	■	■		■				■	balanço térmico/modelos fotométricos simplificados	
	VI.2	Análise de sombras e reflexões (ROY, 1995).										■	balanço térmico/modelos fotométricos simplificados	
	VI.3	Fator de luz solar e Controle dinâmico de iluminação artificial DBRI-tsb13: Petersen, E., Johnsen, K., Grau, K. (GRAU; WITTCHEN, 1999; JOHNSEN; GRAU, 1994).						■						iluminação estática

Quadro 5 – Classificação dos métodos simplificados levantados na bibliografia para a verificação da iluminação natural

														(continua)
Tipo	Nº	Foco principal											Limitação	
		Aplicações (Autor/Fonte)												
		a	b	c	d	e	f	g	h	i	j	k		
VI. Aplicativos computacionais (simulações simplificadas ou ferramenta que remete a resultados pré-simulados) - continua	VI.4	DIAL: Projeto de iluminação natural qualitativo e quantitativo (PAULE; COMPAGNON; SCARTEZZINI, 1995), LESO-DIAL substituído por DIAL Europe (GROOT; ZONNEVELDT; PAULE, 2003) e DIALPlus (LESO-PB, 2013)											implicação apenas no sistema de ilum. artificial	
	VI.5	Building Design Advisor: simulação simplificada (PAPAMICHAEL; LAPORTA; CHAUVET, 1997; PAPAMICHAEL et al., 1999; LBNL, 2006)											Fluxo Dividido/Doe-2 ou Radiosidade/Superlite	
	VI.6	Planilhas: coleções de equações e diagramas (ILB e FIBP).											iluminação estática	
	VI.7	PALN - Percentual de Aproveitamento da Luz Natural (PEREIRA; CLARO; SOUZA, 2006; SOUZA, 2003).											implicação apenas no sistema de ilum. artificial	
	VI.8	Daylight 1-2-3: simulação simplificada (Natural Resources Canadá) *indisponível (REINHART et al., 2007).											proteções solares	
	VI.9	Light Tool: simulação simplificada (LabCon-UFSC/Indelpa) *indisponível (CLARO, 2008).											iluminação estática	
	VI.10	COMFEN: simulação simplificada (LBNL, 2012).											Fluxo Dividido/Doe-2 ou Radiosidade/Superlite	
	VI.11	Back-of-the Envelope Calculator 2.0 - Energy Center of Wisconsin: casos pré-simulados (SCHUETTER, 2010)											balanço térmico/modelos fotométricos simplificados	
	VI.12	Lightsolve: simulação simplificada (Massachusetts Institute of Technology) *indisponível (ANDERSEN; KLEINDIENST; GAGNE, 2010).											balanço térmico/modelos fotométricos simplificados	
	VI.13	IES Virtual Environment (IESVE): VE-Gaia: simulação simplificada (IES, 2010).											iluminação estática	
	VI.14	SPOT: simulação simplificada *indisponível (CORPORATION, 2011).											implicação apenas no sistema de ilum. artificial	
	VI.15	Facade Design Tool: casos pré-simulados (CSBR e LBNL, 2012).											Fluxo Dividido/Doe-2 ou Radiosidade/Superlite	
VI.16	Velux Daylight Visualize (IVERSEN et al., 2013; LABAYRADE et al., 2009; VELUX, 2013).											iluminação estática		

Quadro 5 – Classificação dos métodos simplificados levantados na bibliografia para a verificação da iluminação natural

													(continua)
Tipo	Nº	Foco principal											Limitação
		Aplicações (Autor/Fonte)											
		a	b	c	d	e	f	g	h	i	j	k	
VI. Aplicativos computacionais (simulações simplificadas ou ferramenta que remete a resultados pré-simulados)	VI.17	iDbuild: simulação simplificada (HVIID; NIELSEN; SVENDSEN, 2008; PETERSEN; HVIID, 2013).	■	■	■	■	■	■			■		balanço térmico/modelos fotométricos simplificados
	VI.18	Sky Calc 3.0: casos pré-simulados (T.R.C-H.M.G., 2009; 2014).				■							Fluxo Dividido/Doe-2 ou Radiosidade/Superlite
	VI.19	DesignBuilder: simulação simplificada (LTD, 2014).	■	■	■	■	■	■					Fluxo Dividido/Doe-2 ou Radiosidade/Superlite
	VI.20	Daylight – Dfcalc: planilha que calcula FLD (PETERS, 2004).	■		■								baseado no FLD
	VI.21	DIALux evo: simulação simplificada (GMBH, 2014).	■										iluminação estática
VII. Tipologias	VII.1	Sistema de classificação de componentes do ambiente construído (BAKER; FANCHIOTTI; STEEMERS, 1993).			■	■	■						diretrizes de projeto
	VII.2	Estudo tipológico de vários ambientes testes (GOLAY et al., 1994)	■	■	■	■					■	■	iluminação estática
	VII.3	AVA_ Iluminação Natural - indisponível (ATANASIO; PEREIRA; PEREIRA, 2006).	■	■	■	■							iluminação estática
	VII.4	Diagrama Morfológico (AMORIN, C N D 2007; AMORIN, C N D, 2007).			■	■	■						diretrizes de projeto
VIII. Modelos em escala	VIII.1	Céu artificial/sol artificial (PEREIRA; NOME, 1995; PEREIRA; PEREIRA; GONZALES, 2012).	■	■	■	■	■				■	■	iluminação estática
IX. Ferramentas estatísticas/computacionais baseadas em resultados pré-simulados - continua	IX.1	RLM e Regressão Polinomial Multivariada – Fórmula do Impacto da iluminação (LI; ONG; CHEUNG, 2008).									■		Fluxo Dividido/Doe-2 ou Radiosidade/Superlite
	IX.2	RLM – Economia anual do sistema de iluminação artificial (KRARTI; ERICKSON; HILLMAN, 2005).									■		implicação apenas no sistema de ilum. artificial
	IX.3	RNA – RNA para estimar iluminâncias em salas de aula (estática - medições) (PIZARRO; SOUZA, 2007).	■		■							■	iluminação estática

Quadro 5 – Classificação dos métodos simplificados levantados na bibliografia para a verificação da iluminação natural

														(conclusão)
Tipo	Nº	Aplicações (Autor/Fonte)	Foco principal											Limitação
			a	b	c	d	e	f	g	h	i	j	k	
IX. Ferramentas estatísticas/computacionais baseadas em resultados pré-simulados	IX.4	RNA – RNA para estimar iluminâncias em edifícios de escritório (estática – medições) (KAZANASMAZ; GÜNAYDIN; BINOL, 2009b).	■											iluminação estática
	IX.5	RLM – Consumo Energético considerando o aproveitamento da Iluminação Natural (DIDONÉ; PEREIRA, 2010).								■				não considera ou agrupa o efeito da orientação
	IX.6	RNA – Consumo Energético anual considerando o aproveitamento da Iluminação Natural (WONG; WAN; LAM, 2010).									■			Fluxo Dividido/Doe-2 ou Radiosidade/Superlite
	IX.7	Regressão Polinomial Multivariada: Método Simplificado para Avaliação do Desempenho Dinâmico da Iluminação Natural (MORAES; PEREIRA, 2011) inclusão Fator de Ajuste Orientação (PEREIRA et al., 2012).	■		■				■					baseado no FLD
	IX.8	RLM – Economia de energia nos sistemas de iluminação e condicionamento de ar em função da iluminação natural (efeito na carga térmica) (GIBSON, 2011).									■			Fluxo Dividido/Doe-2 ou Radiosidade/Superlite
	IX.9	RNA – Seleccionador de Ângulo de Aletas (ISAS) baseado nas iluminâncias (HU e OLBINA, 2011)	■											Fluxo Dividido/Doe-2 ou Radiosidade/Superlite
	IX.10	Economia de energia nos sistemas de iluminação e condicionamento de ar em função da iluminação natural (MORET; NORO; PAPAMICHAEL, 2013).									■			Fluxo Dividido/Doe-2 ou Radiosidade/Superlite

APÊNDICE B – RESUMO DAS FERRAMENTAS UTILIZADAS NESTE TRABALHO

Apêndice B1. – *EnergyPlus*: simulação termoenergética

Desenvolvido por uma ação conjunta entre Lawrence Berkeley National Laboratory, the University of Illinois, the U.S. Army Construction Engineering Research Laboratory, GARD Analytics, Inc., Oklahoma State University e outros, com apoio do U.S. Department of Energy, Office of Building Technology, State and Community Programs, o *EnergyPlus* foi liberado em abril de 2001 e é um programa gratuito que pode ser baixado em seu *site* oficial. Foi validado pelo método BESTEST da Standard 140 (ASRHAЕ, 2001).

Trata-se de um simulador dinâmico de desempenho térmico e energético de edificações considerando todos os seus sistemas. Permite a modelagem de parâmetros, tais como climatização, iluminação, cargas internas, propriedades térmicas dos materiais, ventilação e outros fluxos de energia, como águas (CARLO, 2008; FUMO, MAGO e LUCK, 2010). Foi criado com base na junção das melhores características de dois programas, o BLAST e o DOE-2, somada a recursos adicionais originais (MASOSO e GROBLER, 2008).

O programa pode simular dias de projeto ou o ano todo. No primeiro caso, os dados são inseridos durante a modelagem. Já no segundo, utiliza um arquivo climático com 8.760 horas com infrações sobre temperaturas, umidade, radiação, entre outros (CRAWLEY *et al.*, 2001).

O *EnergyPlus* permite a estimativa da economia de energia em função da iluminação natural, considerando condições ambientais, controles de iluminação, gerenciamento do controle de iluminação natural nas aberturas e ocorrência de ofuscamento.

Para o cálculo de iluminação natural, o programa apresenta dois métodos: i) o Fluxo Dividido, derivado do programa DOE-2 e ii) a Radiosidade. O Fluxo Dividido apresenta resultados mais coerentes para ambientes cúbicos e sem divisória (ENERGYPLUS, 2010). Entretanto, segundo Winkelmann e Selkowitz (1985), que integraram o sistema de iluminação no programa DOE-2, o qual posteriormente foi inserido no *EnergyPlus*, este método pode superestimar em até duas vezes ou mais a luz na parede nas porções mais afastadas da abertura. Como limitação, os autores indicam que a profundidade média do ambiente em relação à superfície que contém a abertura não exceda a três vezes a altura do pé

direito. O algoritmo da Radiosidade foi desenvolvido para o programa de iluminação natural SuperLite com o fim de calcular a componente refletida interna e suprir essa limitação do Fluxo dividido (SELKOWITZ *et al.*, 1982). Entretanto, outros autores como Ramos e Ghisi (2010), Didoné e Pereira (2010) e Versage, Melo e Lamberts (2010) comprovaram que ambos os métodos apresentam limitações para modelar o comportamento da luz em ambientes menos profundos.

Apêndice B2.– DIVA: Simulação integrada

Para a simulação integrada dos desempenhos luminoso e térmico da edificação, utilizou-se o *plug-in* DIVA do programa Rhinoceros (JAKUBIEC e REINHART, 2011). O DIVA integra as simulações anuais de disponibilidade de luz natural do programa de simulação Daysim, que, por sua vez, utiliza o Radiance para a modelagem do fenômeno da iluminação natural (REINHART, 2006) com simulações térmicas do programa EnergyPlus. Por ser um *plug-in* do Rhinoceros, permite integração com outros *plug-in*, como o Grasshopper de parametrização ou o Galápagos de Otimização.

O programa Rhinoceros é uma plataforma de modelagem tridimensional utilizada por vários setores da indústria a projeto desde *design* de objetos, peças, máquinas e edificações (MCNEEL e ASSOCIATES, 2014).

O Radiance é um sistema de renderização desenvolvido pelo Lawrence Berkeley Laboratory (LBL), na Califórnia, em parceria com o Ecole Polytechnique Federale de Lausanne (EPFL), na Suíça. Teve início com o estudo do algoritmo do raio traçado (*raytracing*) e posteriormente, demonstrando seu potencial para a economia de energia por meio da viabilização de melhores soluções de projeto de iluminação, obteve financiamento do Departamento de Energia dos EUA e do governo suíço. O programa simula iluminação artificial e natural, predizendo iluminâncias e luminâncias para geometrias complexas e uma ampla gama de materiais sob condições de céu definidas (WARD, 1994). O Radiance e o Daysim utilizam o mesmo formato para parâmetros de entrada.

O Daysim é uma ferramenta de análise de iluminação natural baseada no Radiance, que utiliza o conceito do Coeficiente de Iluminação Natural combinado com o modelo de céu de Perez *et al.* (1990) para predizer séries horárias e sub-horárias de condições de iluminação natural no interior do ambiente, baseado na irradiância

normal direta e difusa horizontal proveniente de um arquivo climático TRY (REINHART e PIERRE-FELIX, 2009). Os dois parâmetros de irradiância são utilizados para determinar a luminância absoluta do hemisfério celeste, assim como para gerar a distribuição relativa das luminâncias do céu que se encontram dentro do espectro dos 15 tipos de céu padrão da CIE (CIE, 2004).

O uso do conceito do Coeficiente de Iluminação Natural torna factível o tempo despedido em simulações para todas as horas do ano, contornando a necessidade de simulação de todo o período do ano para a definição de um perfil anual de iluminação. Uma vez calculado um conjunto completo de Coeficiente de Iluminação Natural para cada ponto de interesse, esse pode ser combinado para qualquer condição de céu a fim de determinar a quantidade de luz natural em determinado ponto sob uma condição de céu particular (REINHART, 2006; BOURGEOIS, REINHART e WARD, 2008).

O Daysim utiliza um modelo comportamental, o *Lightswitch*. Esse modelo pode ser usado para quantificar o potencial da economia de energia de controles automáticos e manuais de iluminação artificial. É feita uma combinação entre perfis de iluminâncias anuais e perfis de ocupação com padrão comportamental baseados em estudos de campo em edificações. Outros parâmetros de entradas são ainda o controle de persianas e o tipo de usuário (ativo ou passivo), além de modelos de avaliação de ofuscamento (REINHART, 2006). A simulação dinâmica permite a simulação sub-horária do uso da iluminação e permite a exportação dos dados de saída da utilização dos sistemas de iluminação e persianas em todas as horas do ano em forma de relatório (BOURGEOIS, REINHART e MACDONALD, 2006).

A integração entre os programas EnergyPlus e Daysim feita pelo DIVA surge como alternativa para contornar a limitação do programa EnergyPlus quanto à superestimação do potencial da iluminação natural. Assim, o programa Daysim fornece os dados referentes ao consumo de iluminação, enquanto o EnergyPlus fornece o consumo total por meio da simulação energética.

Após a simulação anual de iluminação natural, o Daysim gera como dado de saída, além dos valores de medidas de iluminação natural, uma planilha de dados (*.intgain.csv) com o percentual da potência instalada acionado para cada ponto de análise durante todas as horas de ocupação, em função do aproveitamento da iluminação natural. Esse arquivo é utilizado como dado de entrada para o EnergyPlus, como *schedule* de uso do sistema de iluminação artificial. A versão do EnergyPlus interna ao DIVA é a 7.2 e a versão do Daysim é a 3.0,

entretanto o DIVA evoluiu, em especial, na proposição de ferramentas de análise.

Apêndice B3.– Grasshopper – Parametrização

O Grasshopper (RUTTEN, 2011), também *plug-in* do Rhinoceros, é um editor de algoritmo gráfico que permite a geração de formas paramétricas sem a necessidade de escrever a programação da forma tradicional (LAGIUS, NIEMASZ e REINHART, 2010). O programa permite a definição e as variações dos parâmetros. A visualização da programação em modelos arquitetônicos pode ser feita através do Rhinoceros. O Grasshopper e o DIVA se comunicam através de dois componentes: o Componente de Iluminação Natural e o Componente Térmico (Viper). Esses componentes fazem a ligação com o Daysim e EnergyPlus, respectivamente.

Apêndice B4.– MATLAB

Neste trabalho o MATLAB foi utilizado tanto para a amostragem aleatória por Hipercubo Latino quanto para a geração de redes neurais artificiais. O programa MATLAB, amplamente difundido nas diversas áreas da Engenharia, é

uma linguagem para a computação científica com estrutura otimizada para a realização de operações com matrizes. O ambiente MATLAB é composto por uma série de funções pré-definidas para cálculo, leitura e escrita de arquivos e visualização. Este conjunto de funções pode ser facilmente estendido por *toolboxes* dedicadas. Existem *toolboxes* para finanças, tratamento de sinais, econometria e redes neurais. (VICENTE, 2002).

As RNAs computacionais são expressas através de matrizes, existindo várias *tooboxes* (barra de ferramentas) na linguagem MATLAB, por exemplo, a *toolbox* de RNA comercial e a *toolbox* para identificação e controle. Em uma perspectiva ampla de controle supervisionado, existem outras áreas de aplicação, como a visão robótica, o planejamento, o diagnóstico, o controle de qualidade e a análise de dados (SUMATHI e PANEERSELVAM, 2010).

A *toolbox* para Redes Neurais possui ferramentas para projeto, implementação, visualização a simulação de RNA. Suas principais características, de acordo com Mathworks (2011b), são:

- projeto, treinamento e simulação de RNA;
- reconhecimento de padrão, *clustering* e ferramenta de ajuste de dados;
- supervisionamento da rede, incluindo rede alimentada a diante, base radial, LVQ, atraso do tempo, autorregressão não linear (nonlinear autoregressive – NARX) e camada recorrente;
- redes não-supervisionadas, incluindo mapas auto-organizadores e camadas competitivas;
- processamento e pós-processamento para melhorar a eficiência do treinamento da rede e a avaliação do desempenho da rede;
- representação da rede modular para o gerenciamento e a visualização de redes de tamanho arbitrário;
- rotinas para melhorar a generalização e evitar o superajuste; e
- blocos Simulink® para a construção e a avaliação das RNAs e dos blocos avançados para aplicações dos sistemas de controle.

Apêndice B5.– EasyNN-plus

O programa EasyNN-plus (WOLSTENHOLME, 2013b) cria redes neurais multicamadas utilizando o algoritmo da retropropagação do erro baseado na regra delta, empregando otimização através do Gradiente Descendente apresentado no item 2.3.6.1, p.84. A função de ativação tanto na camada interna quanto na de saída é a logarítmica sigmoidal.

Trata-se de um programa em que as etapas de criação das redes neurais são automatizadas. Os dados de entrada são importados em formato separado por vírgulas (*.csv), formato texto, bitmap ou binários. Na importação dos dados indicam-se os vetores dados de entrada e os dados de saída, bem como suas respectivas escalas. Baseado nessa tabela de dados, o programa cria uma rede neural, oferecendo a possibilidade de escolha de número de camadas internas e de número de neurônios nas camadas internas.

O programa oferece a opção de deixar que ele mesmo defina o número de neurônios na camada interna, produzindo a rede neural mais simples que possa aprender os padrões do conjunto de treino. Para tal, o programa executa alguns ciclos de treinamento para otimizar o número de neurônios ocultos (WOLSTENHOLME, 2013a). Essa função foi utilizada em algumas partes deste estudo para fornecer um ponto de partida quanto ao número de neurônios na camada oculta a ser adotado.

Outra função automática é a possibilidade do aumento do número de camadas ocultas e de neurônios nessas camadas. Essa função permite que a rede vá aumentando essas quantidades ao longo do treinamento, conforme o algoritmo do programa solicitar.

Os dados de treinamento podem ser apresentados randomicamente ou ordenados. O programa oferece ferramenta de seleção aleatória para a determinação dos conjuntos de validação e teste ou a possibilidade de importá-los separadamente.

Existem algumas opções preestabelecidas como critério de parada do treinamento que, em alguns casos, podem ser utilizadas agrupadamente.

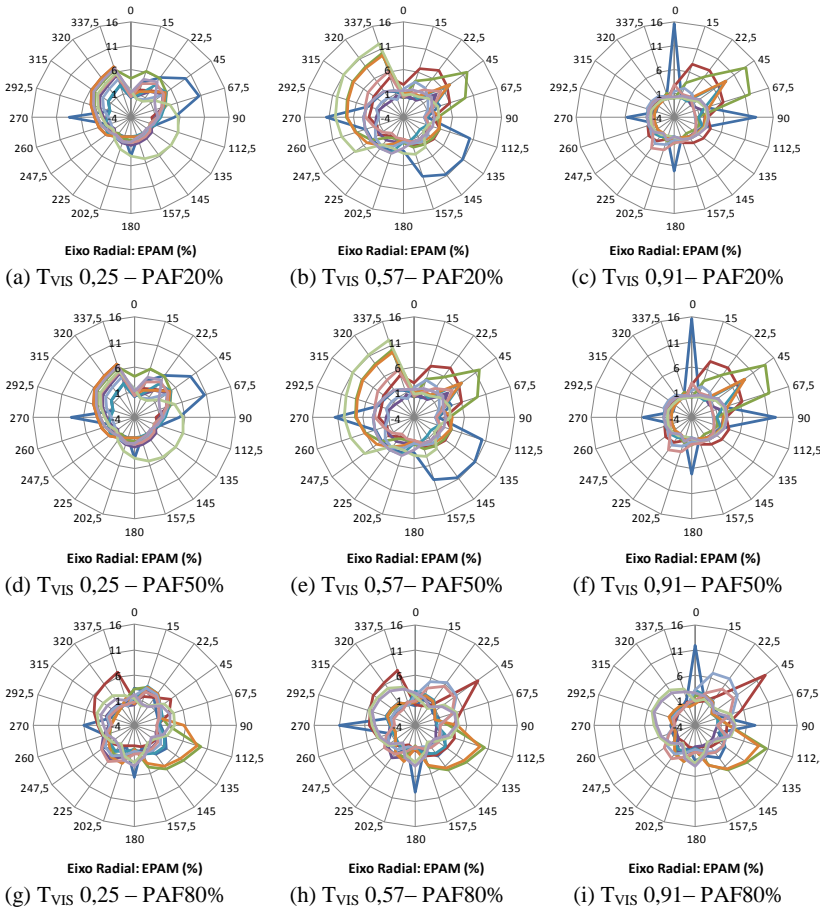
Alguns parâmetros de controle como taxa de aprendizado e de momentum também podem ser alterados, os valores padrão são 0,6 e 0,8. Esses parâmetros também podem ter seus valores alterados automaticamente durante o treinamento da rede, conforme decisão do usuário.

Como ferramenta de análise, o programa oferece gráfico em tempo real mostrando os erros máximos, médios e mínimos do treinamento; e médio da validação. Oferece também gráficos de barras mostrando a importância relativa, a sensibilidade relativa de cada padrão de entrada e o erro relativo de cada caso do treinamento. Todas essas informações, bem como as previsões da rede, podem ser exportadas em arquivo tipo *.csv.

APÊNDICE C – GRÁFICOS DOS EPAMS PARA AS DIFERENTES CODIFICAÇÕES DA VARIÁVEL ORIENTAÇÃO

Neste apêndice são apresentados os gráficos polares da avaliação das diferentes codificações da variável orientação separados por parâmetro de saída. A Figura 132 e a Figura 133 apresentam a codificação cardeal (azimute). Entretanto, na Figura 132 ilustra-se o EPAM de cada uma das 10 RNAs em função de diferentes valores de T_{VIS} combinados com PAF para o parâmetro de saída Consumo Total, enquanto na Figura 133, bem como na Figura 134 e na Figura 135, ilustram-se as médias das 10 RNAs para cada uma das combinações de três valores de PAF e três de T_{VIS} para os quatro parâmetros de saída de energia: Consumo Total, Aquecimento, Resfriamento e Iluminação. Já a Figura 134 ilustra os resultados de EPAM para a codificação cíclica; e a Figura 135 exibe a codificação cardeal + 359° N. No eixo radial são representados os valores de EPAM para cada uma das 10 RNAs testadas em função de cada orientação.

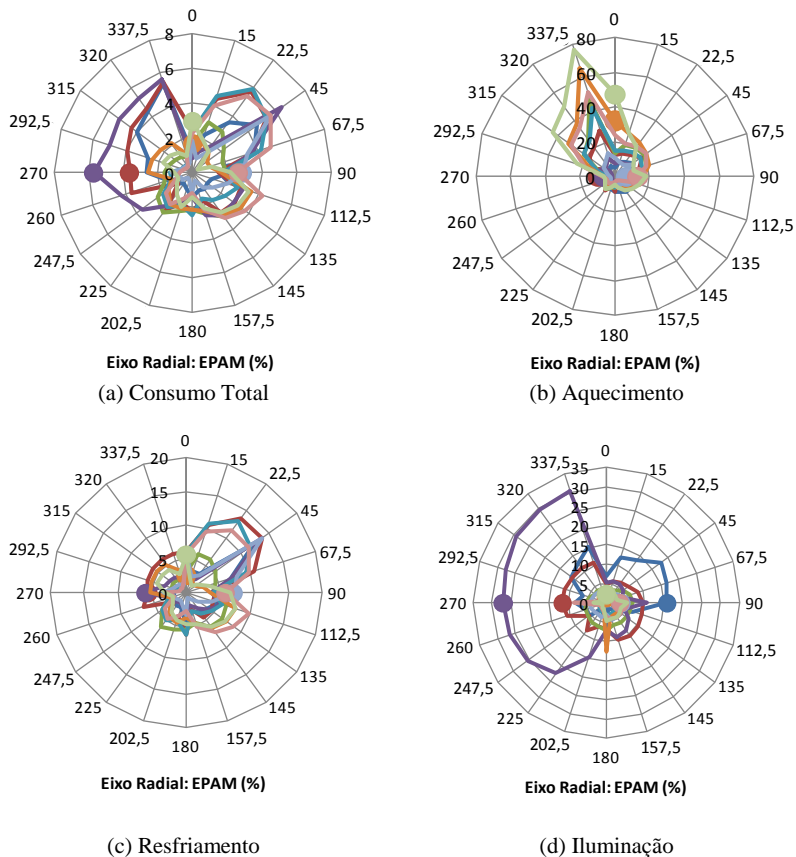
Figura 132 – Comparação entre o desempenho de cada uma das 10 RNAs para cada orientação para as diversas combinações entre T_{VIS} e PAF: Consumo Total




Legenda:

- RNA1 — RNA2 — RNA3 — RNA4 — RNA5
- RNA6 — RNA7 — RNA8 — RNA9 — RNA10

Figura 133 – Comparação entre o desempenho da média das 10 RNAs cada orientação para as diversas combinações entre T_{VIS} e PAF: para os quatro parâmetros de saída e a codificação cardinal

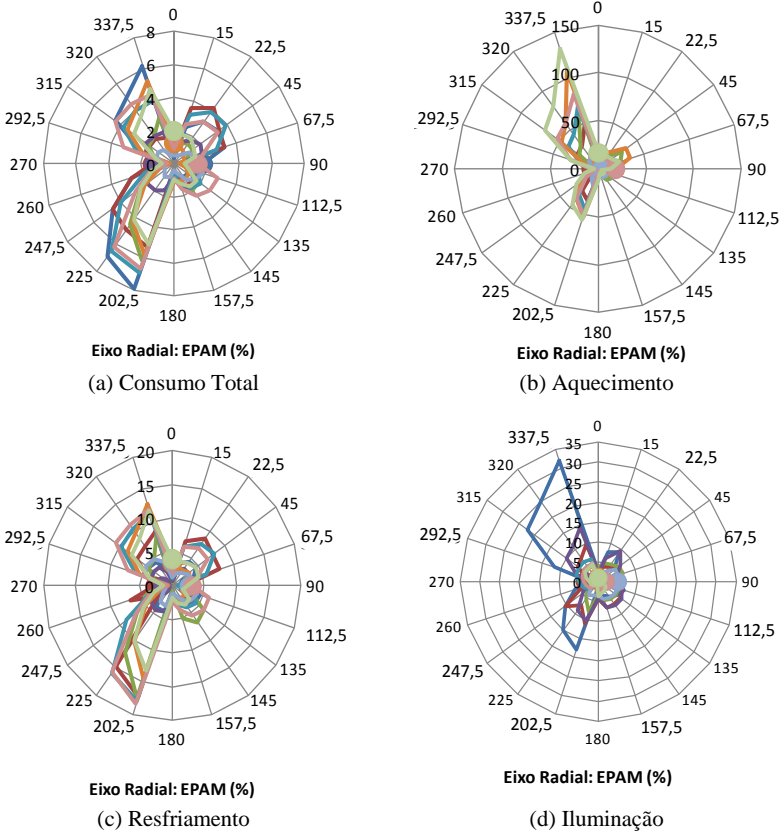


Legenda:



Fonte: Autor.

Figura 134 – Comparação entre o desempenho da média das 10 RNAs para cada orientação para as diversas combinações entre T_{VIS} e PAF: para os quatro parâmetros de saída e a codificação cíclica

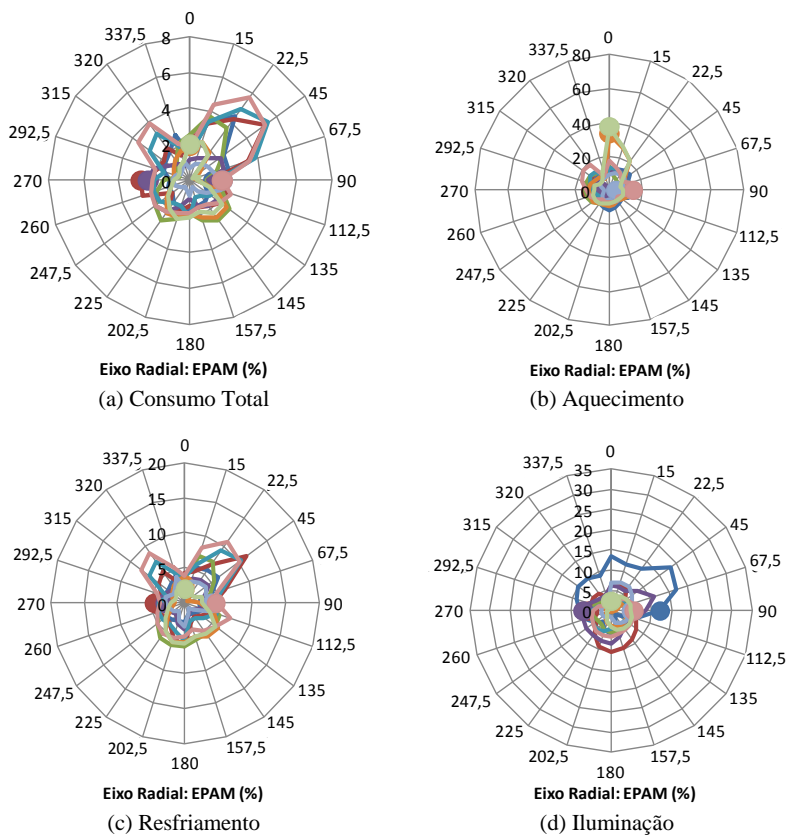


Legenda:


- Tvis 0,25 – PAF 20%
 - Tvis 0,25 – PAF 50%
 - Tvis 0,25 – PAF 80%
- Tvis 0,57 – PAF 20%
 - Tvis 0,57 – PAF 50%
 - Tvis 0,57 – PAF 80%
- Tvis 0,91 – PAF 20%
 - Tvis 0,91 – PAF 50%
 - Tvis 0,91 – PAF 80%

Fonte: Autor.

Figura 135 – Comparação entre o desempenho da média das 10 RNAs para cada orientação para as diversas combinações entre T_{vis} e PAF: para os quatro parâmetros de saída e a codificação cardinal + 359° N



Legenda:

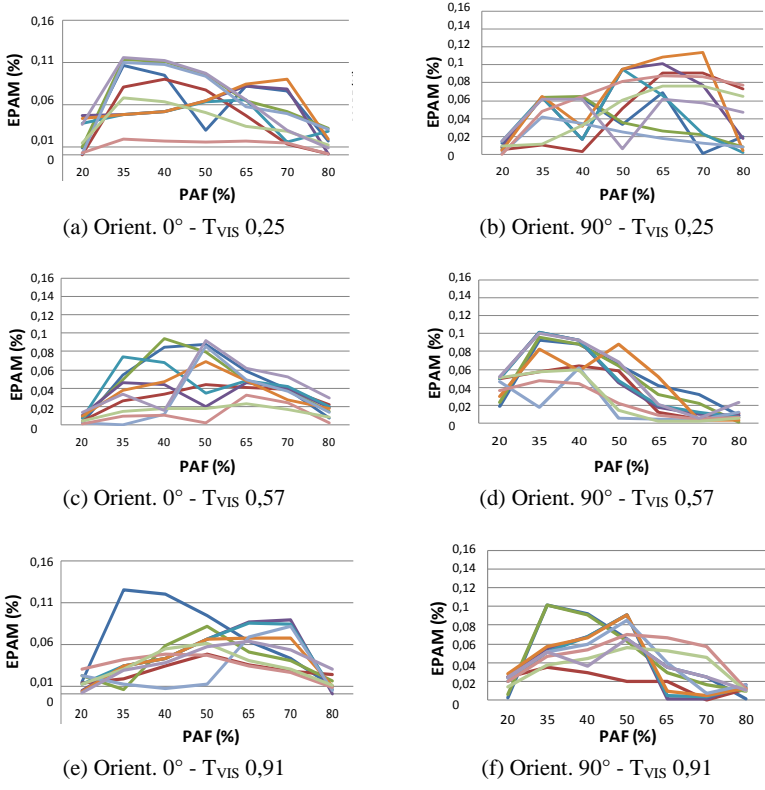


Fonte: Autor.

APÊNDICE D – GRÁFICOS DOS EPAMS PARA AS DIFERENTES QUANTIDADES DE CASOS DE PAF E T_{VIS}

Neste apêndice são apresentados os gráficos dos EPAMs para cada rede referente ao Consumo Total, conforme diferentes quantidades de casos de T_{VIS} e PAF apresentados no treinamento. Os resultados são apresentados em função da Orientação, T_{VIS} e PAF. Os EPAMs apresentados nos gráficos não foram multiplicados por 100, apresentando-se os valores sem a transformação em percentual. A Figura 136 e a Figura 137 apresentam os gráficos para avaliação conforme o aumento do PAF para as orientações 0° e 90° e para as orientações 180° e 270° , respectivamente. Já a Figura 138 e a Figura 139 apresentam os gráficos para avaliação conforme o aumento de T_{VIS} para as mesmas orientações, respectivamente.

Figura 136 – Comparação entre EPAM médio das 10 redes separado isolando-se PAF para orientação 0° e 90°



Análise PAF (Norte)


Análise PAF (Leste)

Legenda:


- RNA1
- RNA2
- RNA3
- RNA4
- RNA5
- RNA6
- RNA7
- RNA8
- RNA9
- RNA10

Fonte: Autor.


Figura 137 – Comparação entre EPAM médio das 10 redes separado isolando-se PAF para orientação 180° e 270°




(a) Orient. 180° - T_{VIS} 0,25




(b) Orient. 270° - T_{VIS} 0,25




(c) Orient. 180° - T_{VIS} 0,57



(d) Orient. 270° - T_{VIS} 0,57



(e) Orient. 180° - T_{VIS} 0,91



(f) Orient. 270° - T_{VIS} 0,91

Análise PAF (Sul)

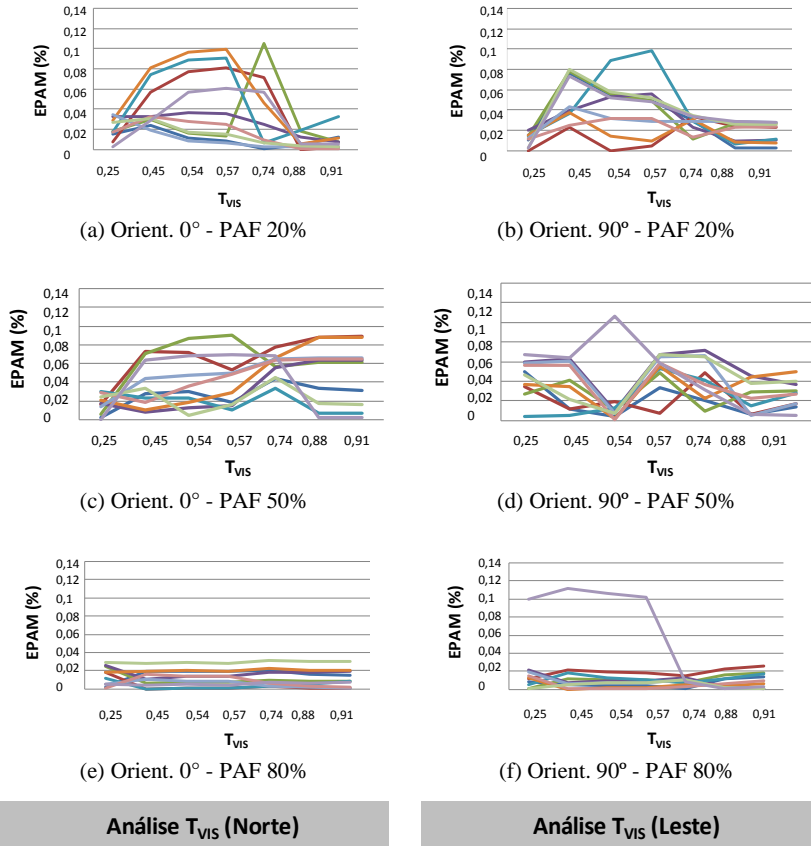
Análise PAF (Oeste)

Legenda:



Fonte: Autor.

Figura 138 – Comparação entre EPAM médio das 10 redes separado isolando-se T_{VIS} para orientação 0° e 90°




Legenda:


- RNA1
- RNA2
- RNA3
- RNA4
- RNA5
- RNA6
- RNA7
- RNA8
- RNA9
- RNA10

Fonte: Autor.


Figura 139 – Comparação entre EPAM médio das 10 redes separado isolando-se T_{VIS} para orientação 180° e 270°




(a) Orient. 180° - PAF 20%




(b) Orient. 270° - PAF 20%




(c) Orient. 180° - PAF 50%



(d) Orient. 270° - PAF 50%



(e) Orient. 180° - PAF 80%



(f) Orient. 270° - PAF 80%

Análise T_{VIS} (Sul)

Análise T_{VIS} (Oeste)

Legenda:



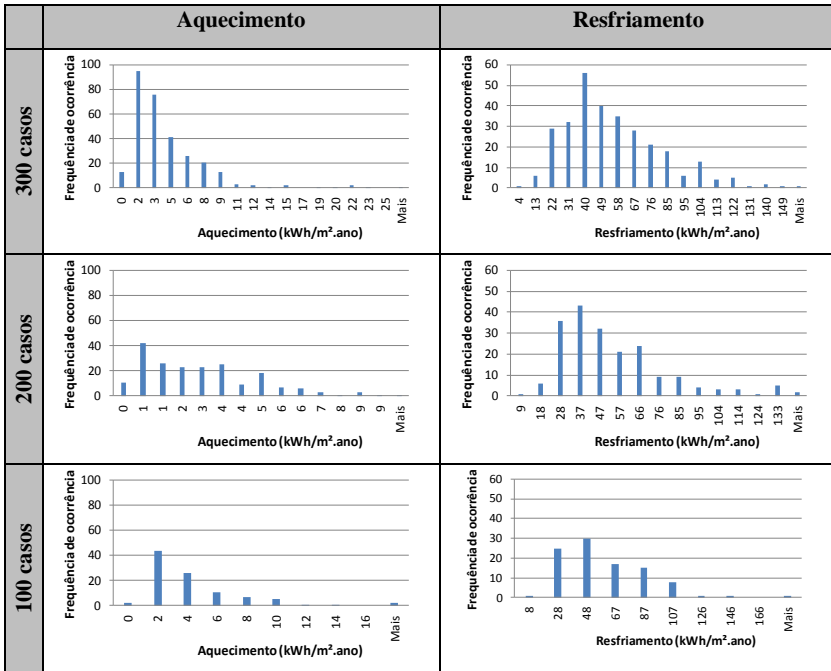
Fonte: Autor.

APÊNDICE E – TESTE DE NORMALIDADE DAS AMOSTRAS

O teste Kolmogorov-Smirnov foi realizado para cada um dos 11 parâmetros de saída (cinco de energia e seis de iluminação natural) para a amostragem de 300 casos. Com 95% de confiança, todos os conjuntos tiveram a hipótese de normalidade descartada, com exceção do conjunto de consumo total energético quando testado em escala logarítmica. Os histogramas de frequência de ocorrência das amostras em escala real foram apresentados da Figura 140 à Figura 144 e em escala logarítmica na Figura 145 e na Figura 146.

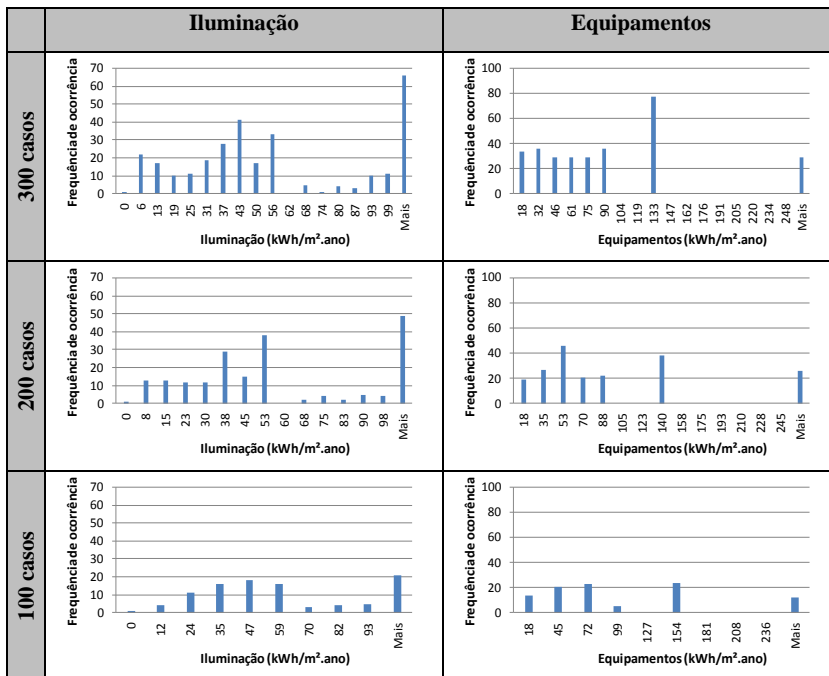
Diante desse resultado, foram gerados os gráficos de histograma de frequência de ocorrência de todos os parâmetros de saída para as demais amostragens, 200 e 100 casos, como ilustram os gráficos apresentados da Figura 140 à Figura 144. Os histogramas para sDA 30% e para Consumo total já foram apresentados na Figura 91, p.44 do Capítulo 7.

Figura 140 – Perfil de distribuição das amostras por Hipercubo latino para 300, 200 e 100 casos por parâmetro de saída: Aquecimento e Resfriamento




Fonte: Autor.

Figura 141 – Perfil de distribuição das amostras por Hipercubo latino para 300, 200 e 100 casos por parâmetro de saída: Iluminação e Equipamentos



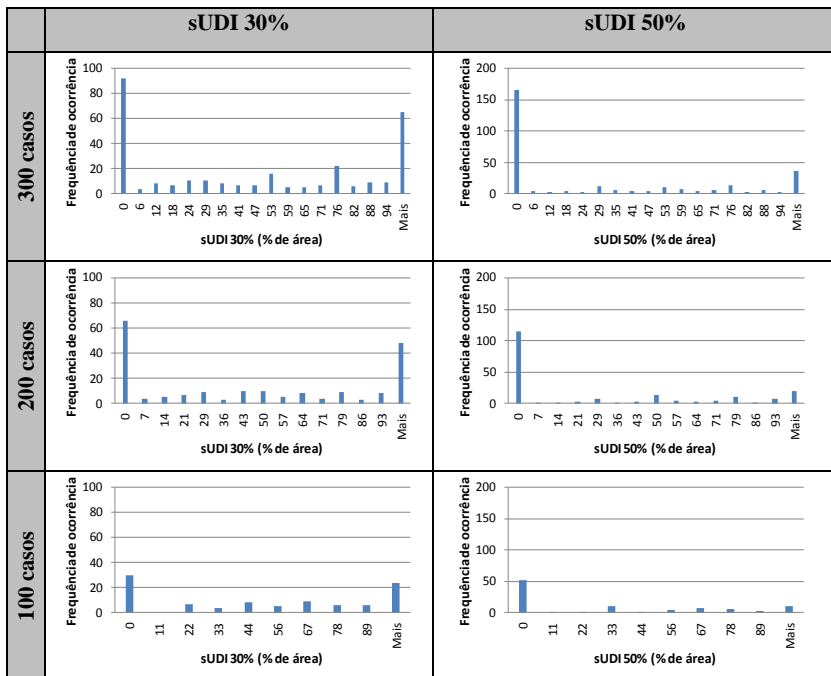
Fonte: Autor.

Figura 142 – Perfil de distribuição das amostras por Hipercubo latino para 300, 200 e 100 casos por parâmetro de saída: sDA 50%



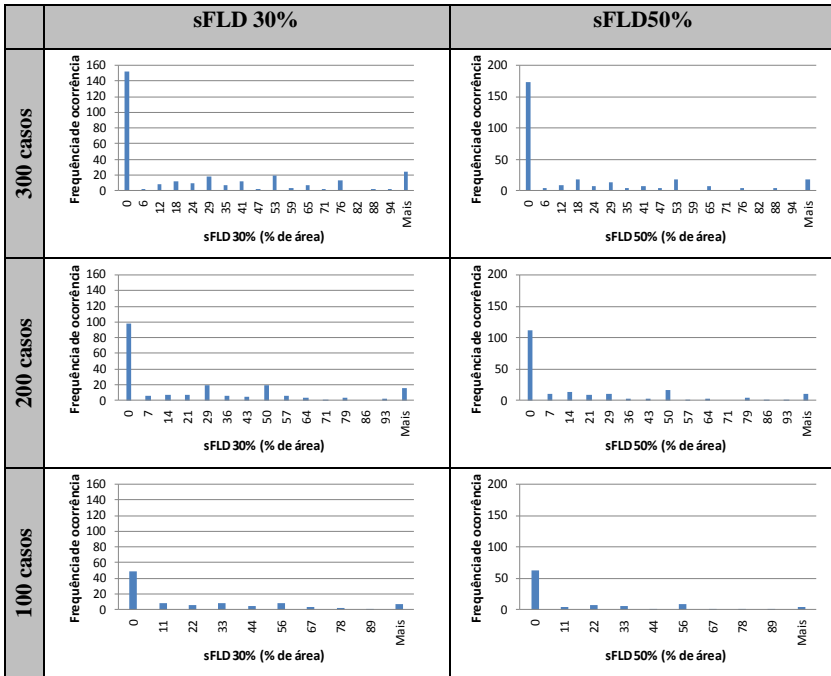
Fonte: Autor.

Figura 143 – Perfil de distribuição das amostras por Hiper-cubo latino para 300, 200 e 100 casos por parâmetro de saída: sUDI 30% e sUDI 50%



Fonte: Autor.

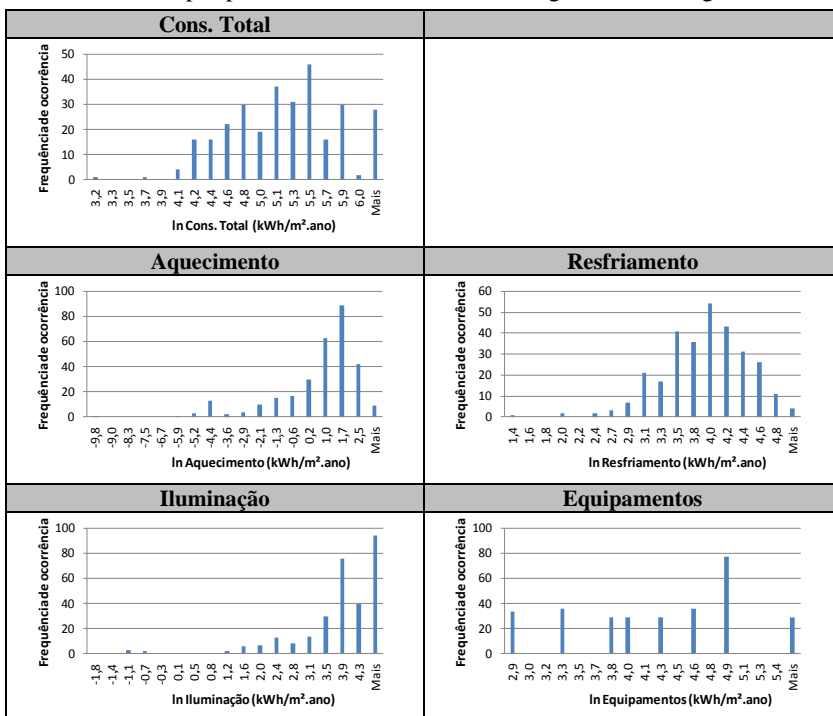
Figura 144 – Perfil de distribuição das amostras por Hipercubo latino para 300, 200 e 100 casos por parâmetro de saída: sFLD30% e sFLD 50%



Fonte: Autor.

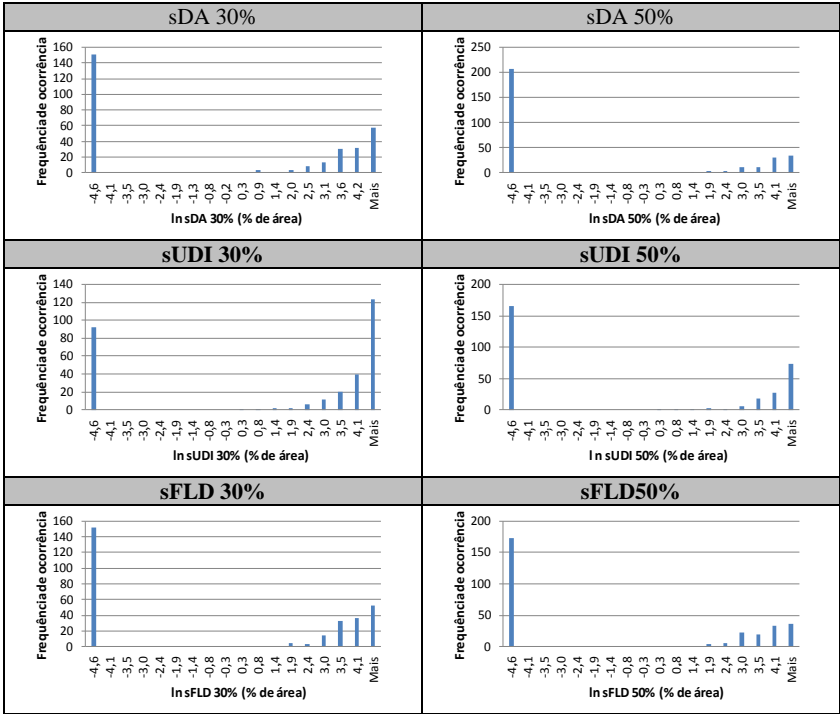
Foi aplicada a escala logarítmica para a amostragem de 300 casos para verificar uma possível aproximação da distribuição normal. Houve um excesso de deslocamento, configurando-se uma distribuição assimétrica à direita, de acordo com a Figura 145 e a Figura 146.

Figura 145 – Perfil de distribuição das amostras por Hipercubo latino para 300 casos por parâmetro de saída em escala logarítmica: energia



Fonte: Autor.

Figura 146 – Perfil de distribuição das amostras por Hipercubo latino para 300 casos por parâmetro de saída em escala logarítmica: iluminação natural



Fonte: Autor.

APÊNDICE F – EQUAÇÕES DA PROPOSTA DO ZONEAMENTO DE ILUMINAÇÃO NATURAL

Neste apêndice são apresentadas as equações propostas no item 8.3.1.1, p.324. Da Equação 35 à 49 são apresentadas as equações referentes à zona Z2 (Z1+Z2) e da Equação 50 à 56, as referentes à zona Z1. As duas equações utilizadas no exemplo de aplicação do item 8.3.2.2 são aqui apenas referenciadas.

Quanto às equações referentes à zona Z2 (Z1+Z2), a Equação 35 refere-se à proposta considerando todos os modelos. Na regressão da Equação 36 foram excluídos os modelos com PAF 80%. As Equações 37 e 38 consideram os conjuntos de 300 lux e 500 lux, respectivamente, de forma individual. As Equações 39 a 42 são de 300 lux para PAF 20%, 40%, 60% e 80%, respectivamente. As Equações 43 a 45 são equações de 500 lux para os mesmos valores de PAF, com exceção do PAF 80%, que foi apresentado no exemplo do item 8.3.2.2, Equação 32. Por fim, as Equações 46 a 49 referem-se ao conjunto de 300 lux para PAF 20% para as orientações Norte, Sul, Leste e Oeste, nesta ordem.

Quanto às equações referentes à zona Z1, as Equações 50 a 53 são equações de 300 lux para PAF 20%, 40%, 60% e 80%, respectivamente. Enquanto as Equações 54 a 56 referem-se aos mesmos PAFs para 500 lux, com exceção do PAF 80%, que foi apresentado no exemplo do item 8.3.2.2, Equação 31.

Para evitar o excesso de repetição, a legenda com o significado de cada variável independente das equações será apresentada apenas na Equação 35. As variáveis independentes são as mesmas em todas as equações. Entretanto, vão sendo removidas conforme os agrupamentos forem sendo divididos em subgrupos.

Z2 (Z1+Z2) - EQUAÇÃO I - Todos os modelos (300 lux e 500 lux)

$$2 * A_{ZONA} = EXP[(1,6109 * T_{VIS}) + (0,0003 * ORIENT) + \left(48,5658 + 21 * \frac{1}{DA_{alvo}}\right) + \left(0,0022 * \frac{1}{(1-R)}\right) + (-0,2109 * PAF) + (0,0388 * \theta) + (-0,0016 * E)] \quad (35)$$

Onde:

A_{zona} = área total de todas as superfícies da zona;

T_{VIS} = transmissão visível;

$ORIENT$ = orientação da abertura;

DA_{alvo} = Autonomia da Luz Natural mínima a ser obtida na zona-alvo;

R = refletância média de todas as superfícies do ambiente ponderadas pelas respectivas áreas;

PAF_{zona} = Percentual de Abertura da Fachada (considerando a largura da janela);

θ = ângulo efetivo de céu; e

E_{alvo} = iluminância-alvo para o cálculo do DA_{alvo} .

Z2 (Z1+Z2) - EQUAÇÃO II - Excluindo os modelos com PAF 80% (300 lux e 500 lux)

$$2 * A_{ZONA} = EXP[(1,7094 * T_{VIS}) + (0,0003 * ORIENT) + \left(-24,3099 * \frac{1}{DA_{alvo}}\right) + \left(0,2032 * \frac{1}{(1-R)}\right) + (-2,5973 * PAF) + (0,0827 * \theta) + (0 - 0,0016 * E)] \quad (36)$$

Z2 (Z1+Z2) - EQUAÇÃO III - Separando o conjunto anterior – 300 lux

$$2 * A_{ZONA} = EXP[(1,4794 * T_{VIS}) + (0,0003 * ORIENT) + \left(-13,2572 * \frac{1}{DA_{alvo}}\right) + \left(0,2311 * \frac{1}{(1-R)}\right) + (-1,9856 * PAF) + (0,0673 * \theta)] \quad (37)$$

Z2 (Z1+Z2) - EQUAÇÃO IV - Separando o conjunto anterior –
500 lux

$$2 * A_{ZONA} = EXP[(0,0673 * T_{VIS}) + (0,0003 * ORIENT) + (-72,6539 * \frac{1}{DA_{alvo}}) + (0,1753 * \frac{1}{(1-R)}) + (-3,2089 * PAF) + (0,0982 * \theta)] \quad (38)$$

Z2 (Z1+Z2) - EQUAÇÃO V - Conjunto 300 lux separado por
PAF: PAF 20%

$$2 * A_{ZONA} = EXP[(2,1897 * T_{VIS}) + (0,0006 * ORIENT) + (72,9515 * \frac{1}{DA_{alvo}}) + (0,2387 * \frac{1}{(1-R)})] \quad (39)$$

Z2 (Z1+Z2) - EQUAÇÃO VI - Z2 (Z1+Z2) - Conjunto 300 lux
separado por PAF: PAF 40%

$$2 * A_{ZONA} = EXP[(1,0771 * T_{VIS}) + (0,0002 * ORIENT) + (108,2683 * \frac{1}{DA_{alvo}}) + (0,2146 * \frac{1}{(1-R)})] \quad (40)$$

Z2 (Z1+Z2) - EQUAÇÃO VII - Conjunto 300 lux separado por
PAF: PAF 60%

$$2 * A_{ZONA} = EXP[(1,1714 * T_{VIS}) + (0,0002 * ORIENT) + (109,4529 * \frac{1}{DA_{alvo}}) + (0,2401 * \frac{1}{(1-R)})] \quad (41)$$

Z2 (Z1+Z2) - EQUAÇÃO VIII - Conjunto 300 lux separado por PAF: PAF 80%

$$2 * A_{ZONA} = EXP[(1,2976 * T_{VIS}) + (0,0002 * ORIENT) + \left(106,9631 * \frac{1}{DA_{atvo}}\right) + \left(0,2780 * \frac{1}{(1-R)}\right)] \quad (42)$$

Z2 (Z1+Z2) - EQUAÇÃO IX - Conjunto 500 lux separado por PAF: PAF 20%

$$2 * A_{ZONA} = EXP[(3,1635 * T_{VIS}) + (0,0003 * ORIENT) + \left(53,8423 * \frac{1}{DA_{atvo}}\right) + \left(0,1392 * \frac{1}{(1-R)}\right)] \quad (43)$$

Z2 (Z1+Z2) - EQUAÇÃO X - Conjunto 500 lux separado por PAF: PAF 40%

$$2 * A_{ZONA} = EXP[(1,3880 * T_{VIS}) + (0,0003 * ORIENT) + \left(97,6698 * \frac{1}{DA_{atvo}}\right) + \left(0,1665 * \frac{1}{(1-R)}\right)] \quad (44)$$

Z2 (Z1+Z2) - EQUAÇÃO XI - Conjunto 500 lux separado por PAF: PAF 60%

$$2 * A_{ZONA} = EXP[(1,2669 * T_{VIS}) + (0,0003 * ORIENT) + \left(101,0453 * \frac{1}{DA_{alvo}}\right) + \left(0,2203 * \frac{1}{(1 - R)}\right)] \quad (45)$$

Z2 (Z1+Z2) - EQUAÇÃO XII - Conjunto 500 lux separado por PAF: PAF 80%

(conforme apresentado na Equação 33, no Capítulo 8, p. 338).

Z2 (Z1+Z2) - EQUAÇÃO XIII - Conjunto 300 lux, PAF 20% – separado por orientação: Norte

$$2 * A_{ZONA} = EXP[(1,1614 * T_{VIS}) + \left(108,54 * \frac{1}{DA_{alvo}}\right) + \left(0,0754 * \frac{1}{(1 - R)}\right)] \quad (46)$$

Z2 (Z1+Z2) - EQUAÇÃO XIV - Conjunto 300 lux, PAF 20% – separado por orientação: Sul

$$2 * A_{ZONA} = EXP[(3,4193 * T_{VIS}) + \left(53,9924 * \frac{1}{DA_{alvo}}\right) + \left(0,1970 * \frac{1}{(1 - R)}\right)] \quad (47)$$

Z2 (Z1+Z2) - EQUAÇÃO XV - Conjunto 300 lux, PAF 20% – separado por orientação: Leste

$$2 * A_{ZONA} = EXP[(2,5010 * T_{VIS}) + \left(53,9950 * \frac{1}{DA_{alvo}}\right) + (0,5059 * \frac{1}{(1-R)})] \quad (48)$$

Z2 (Z1+Z2) - EQUAÇÃO XVI - Conjunto 300 lux, PAF 20% – separado por orientação: Oeste

$$2 * A_{ZONA} = EXP[(1,6771 * T_{VIS}) + \left(91,0742 * \frac{1}{DA_{alvo}}\right) + (0,1763 * \frac{1}{(1-R)})] \quad (49)$$

Z1 - EQUAÇÃO I - Conjunto 300 lux separado por PAF: PAF 20%

$$2 * A_{ZONA} = EXP[(3,0173 * T_{VIS}) + (0,0006 * ORIENT) + \left(89,9218 * \frac{1}{DA_{alvo}}\right) + (0,1997 * \frac{1}{(1-R)})] \quad (50)$$

Z1 - EQUAÇÃO II - Conjunto 300 lux separado por PAF: PAF
40%

$$2 * A_{ZONA} = EXP[(1,2155 * T_{VIS}) + (0,0001 * ORIENT) + \left(171,8956 * \frac{1}{DA_{alvo}}\right) + (0,1844 * \frac{1}{(1-R)})] \quad (51)$$

Z1 - EQUAÇÃO III - Conjunto 300 lux separado por PAF: PAF
60%

$$2 * A_{ZONA} = EXP[(1,1504 * T_{VIS}) + (0,0002 * ORIENT) + \left(182,6612 * \frac{1}{DA_{alvo}}\right) + (0,1566 * \frac{1}{(1-R)})] \quad (52)$$

Z1 - EQUAÇÃO IV - Conjunto 300 lux separado por PAF: PAF
80%

$$2 * A_{ZONA} = EXP[(1,2612 * T_{VIS}) + (0,0002 * ORIENT) + \left(176,1015 * \frac{1}{DA_{alvo}}\right) + (0,2108 * \frac{1}{(1-R)})] \quad (53)$$

Z1 - EQUAÇÃO V - Conjunto 500 lux separado por PAF: PAF
20%

$$2 * A_{ZONA} = EXP[(3,0455 * T_{VIS}) + (0,0006 * ORIENT) + \left(72,1886 * \frac{1}{DA_{alvo}}\right) + (0,1459 * \frac{1}{(1 - R)})] \quad (54)$$

Z1 - EQUAÇÃO VI - Conjunto 500 lux separado por PAF: PAF
40%

$$2 * A_{ZONA} = EXP[(2,1411 * T_{VIS}) + (0,0002 * ORIENT) + \left(128,1781 * \frac{1}{DA_{alvo}}\right) + (0,2022 * \frac{1}{(1 - R)})] \quad (55)$$

Z1 - EQUAÇÃO VII - Conjunto 500 lux separado por PAF: PAF
60%

$$2 * A_{ZONA} = EXP[(1,3740 * T_{VIS}) + (0,0003 * ORIENT) + \left(160,4716 * \frac{1}{DA_{alvo}}\right) + (0,1779 * \frac{1}{(1 - R)})] \quad (56)$$

Z1 - EQUAÇÃO VIII - Conjunto 500 lux separado por PAF:
PAF 80%

(conforme apresentado na Equação 32, no Capítulo 8, p.343).

APÊNDICE G –MAPA-RESUMO DAS PERGUNTAS E DAS RESPOSTAS DA TESE

A versão digital desta tese apresenta um mapa-resumo estruturado conforme a Figura 12, p.103, apresentada no capítulo do método geral, respeitando o mesmo cabeçalho e a ordem das informações. O mapa relaciona o capítulo em que cada pergunta de pesquisa apresentada no item 3.2, p. 105 (Etapa 1), foi abordada com as perguntas da Etapa 2 do método e as ações metodológicas da Etapa 3, seguidas dos seus respectivos resultados.

O Capítulo 8 não foi abordado nesse mapa por adotar método-base diferenciado, aplicação de uma RNA e não investigação.

A Figura 147 ilustra o mapa-resumo em miniatura, disponível em tamanho real (tamanho A1) na versão digital da tese.

Figura 147 – Miniatura do mapa- resumo relacionando método e resultados

CABEÇALHO (FIGURA 12)		MÉTODOS		RESULTADOS	
CAPÍTULO 4					
CAPÍTULO 5					
CAPÍTULO 6					
CAPÍTULO 7					
CONCLUSÃO GERAL DO TRABALHO					

ANEXO

Este anexo apresenta os valores padrão do MATLAB para critérios de parada do treinamento para os algoritmos utilizados neste trabalho.

Tabela com valores padrão para Gradiente Descendente: função traingd

Tabela 34 – Valores padrão função traingd

et.trainParam.epochs	1000	Maximum number of epochs to train
net.trainParam.goal	0	Performance goal
net.trainParam.showCommandLine	0	Generate command-line output
net.trainParam.showWindow	1	Show training GUI
net.trainParam.lr	0.01	Learning rate
net.trainParam.max_fail	6	Maximum validation failures
net.trainParam.min_grad	1e-5	Minimum performance gradient
net.trainParam.show	25	Epochs between displays (NaN for no displays)
net.trainParam.time	inf	Maximum time to train in seconds

Fonte: The Mathworks Inc.(2014).

**Tabela com valores padrão para Gradiente Descendente:
função trainbr**

Tabela 35 – Valores padrão função trainbr

net.trainParam.epochs	1000	Maximum number of epochs to train
net.trainParam.goal	0	Performance goal
net.trainParam.mu	0.005	Marquardt adjustment parameter
net.trainParam.mu_dec	0.1	Decrease factor for mu
net.trainParam.mu_inc	10	Increase factor for mu
net.trainParam.mu_max	1e10	Maximum value for mu
net.trainParam.max_fail	0	Maximum validation failures
net.trainParam.mem_reduc	1	Factor to use for memory/speed tradeoff
net.trainParam.min_grad	1e-7	Minimum performance gradient
net.trainParam.show	25	Epochs between displays (NaN for no displays)
net.trainParam.showCommandLine	0	Generate command-line output
net.trainParam.showWindow	1	Show training GUI
net.trainParam.time	inf	Maximum time to train in seconds

Fonte: The Mathwors Inc.(2014).

**Tabela com valores padrão para Gradiente Descendente:
função trainlm**

Tabela 36– Valores padrão função trainlm

net.trainParam.epochs	1000	Maximum number of epochs to train
net.trainParam.goal	0	Performance goal
net.trainParam.max_fail	6	Maximum validation failures
net.trainParam.min_grad	1e-7	Minimum performance gradient
net.trainParam.mu	0.001	Initial mu
net.trainParam.mu_dec	0.1	mu decrease factor
net.trainParam.mu_inc	10	mu increase factor
net.trainParam.mu_max	1e10	Maximum mu
net.trainParam.show	25	Epochs between displays (NaN for no displays)
net.trainParam.showCommandLine	0	Generate command-line output
net.trainParam.showWindow	1	Show training GUI
net.trainParam.time	inf	Maximum time to train in seconds

Fonte: The Mathwors Inc.(2014).

Tese apresentada ao Programa de Pós-
Graduação em Engenharia Civil,
Departamento de Engenharia Civil, do Centro
Tecnológico da Universidade Federal de Santa
Catarina, como requisito para obtenção do
Título de Doutor em Engenharia Civil

Orientador: Prof. Fernando Oscar Ruttkay
Pereira, Ph.D.

Coorientador: Prof. Dr. Konstantinos
Papamichael, Ph.D.

Florianópolis, 2015

