

Utilização de redes neurais para estimativa da resistência à compressão do concreto simples

Use of neural networks to estimate the compressive strength of simple concrete

DOI:10.34117/bjdv6n10-424

Recebimento dos originais: 15/09/2020

Aceitação para publicação: 20/10/2020

Stéphanie Oliveira Nina Rocha

Especialista em Gerenciamento de Projetos

Instituição: Universidade Estadual de Montes Claros – Montes Claros, MG, Brasil

Programa de Pós-graduação em Modelagem Computacional e Sistemas

Campus Universitário Prof. Darcy Ribeiro

Endereço: Av. Prof. Rui Braga, s/n - Vila Mauriceia, Montes Claros - MG, 39401-089

e-mail: stephanie@grupoelemental.com.br

Nilton Alves Maia

Doutor em Engenharia Elétrica

Instituição: Universidade Estadual de Montes Claros – Montes Claros, MG, Brasil

Programa de Pós-graduação em Modelagem Computacional e Sistemas

Campus Universitário Prof. Darcy Ribeiro

Endereço: Av. Prof. Rui Braga, s/n - Vila Mauriceia, Montes Claros - MG, 39401-089

e-mail: nilton.maia@unimontes.br

Álvaro Barbosa de Carvalho Júnior

Doutor em Engenharia Mecânica

Instituição: Universidade Estadual de Montes Claros – Montes Claros, MG, Brasil

Programa de Pós-graduação em Modelagem Computacional e Sistemas

Campus Universitário Prof. Darcy Ribeiro

Endereço: Av. Prof. Rui Braga, s/n - Vila Mauriceia, Montes Claros - MG, 39401-089

e-mail: alvaro.junior@unimontes.br

Mikaella Pricila Alves Dias

Especialista em Sistemas Elétricos de Potência.

Instituição: Universidade Estadual de Montes Claros – Montes Claros, MG, Brasil

Programa de Pós-graduação em Modelagem Computacional e Sistemas

Campus Universitário Prof. Darcy Ribeiro

Endereço: Av. Prof. Rui Braga, s/n - Vila Mauriceia, Montes Claros - MG, 39401-089

e-mail: mikaellapricila@gmail.com

Renê Rodrigues Veloso

Doutor em Ciência da Computação

Instituição: Universidade Estadual de Montes Claros – Montes Claros, MG, Brasil

Programa de Pós-graduação em Modelagem Computacional e Sistemas

Campus Universitário Prof. Darcy Ribeiro

Endereço: Av. Prof. Rui Braga, s/n - Vila Mauriceia, Montes Claros - MG, 39401-089

RESUMO

O concreto é um material que possui inúmeras variáveis quanto ao seu uso, pois fatores como o tipo de cimento, agregados, aditivos, quantidade de água e tempo de cura, podem influenciar sua resistência à compressão. Buscando desenvolver uma metodologia para investigar os efeitos dessas variáveis na resistência à compressão do concreto, foram desenvolvidas Redes Neurais Artificiais, do tipo *Perceptron* de Múltiplas Camadas (MLP), utilizando os algoritmos *back-propagation* (BP) e *Levenberg-Marquardt* (LM) para verificar qual dessas redes se comporta melhor diante das variáveis. Nessa pesquisa também foram utilizadas Redes de Base Radiais (RBF) com o auxílio do *software Matlab*. Essas redes foram utilizadas com o intuito de estimar a resistência à compressão do concreto passível de uso em diversas aplicações. Depois de treinadas, ambas as redes demonstraram resultados satisfatórios, em especial a RBF, que apresentou um erro de 0.0129 com um tempo de processamento de 4.7813 segundos. Os resultados preliminares desse estudo mostraram a potencialidade de uso da inteligência artificial na engenharia civil, a qual pode auxiliar nas etapas de dosagem do concreto.

Palavras-chave: Concreto, Redes Neurais, MLP, RBF.

ABSTRACT

Concrete is a material that has numerous variables regarding its use, since factors such as the type of cement, aggregates, additives, amount of water and curing time, can influence its compressive strength. In order to develop a methodology to investigate the effects of these variables on the compressive strength of concrete, Artificial Neural Networks, of the Multilayer Perceptron type (MLP), were developed, using the back-propagation (BP) and Levenberg-Marquardt (LM) algorithms to verify which of these networks behaves better in view of the variables. In this research, Radial Base Networks (RBF) were also used with the aid of the Matlab software. These networks were used to estimate the compressive strength of passive concrete in use in several applications. After being trained, both networks presented satisfactory results, especially the RBF, which presented an error of 0.0129 with a processing time of 4.7813 seconds. The preliminary results of this study showed the potential use of artificial intelligence in civil engineering, which can assist in the concrete dosing steps.

Keywords: Concrete, Neurons Network, MLP, RBF.

1 INTRODUÇÃO

Desde as primeiras calculadoras inventadas no século I, passando pelos filmes de ficção científica, e chegando até os computadores atuais que recebem comandos inteligentes, o conceito de Inteligência Artificial (IA) vem sendo modificando ao longo do tempo. Muitos cientistas contribuíram para o desenvolvimento da IA, contudo, o termo IA surgiu no final da década de 1950, após um encontro entre pesquisadores de diversas áreas que possuíam um objetivo em comum “criar máquinas inteligentes” (ARTERO, 2009).

As utilizações das IA's são diversas, podendo ser aplicadas no processo de linguagem natural, no reconhecimento de padrões, na visão computacional e na robótica. Segundo Rosa (2011), entre os mais

importantes modelos de IA's destacam-se: o processamento de línguas naturais, a visão artificial, a robótica, a interferência lógica, a lógica de predicados e as redes neurais artificiais.

As Redes Neurais Artificiais (RNAs) se assemelham a um processador inspirado no comportamento do cérebro humano, que utiliza técnicas computacionais para armazenar um conhecimento experimental e torná-lo disponível para uso, sendo sua capacidade de aprendizagem um dos pontos mais ressaltados (HAYKIN, 2001).

Atualmente, podem ser encontrados diversos tipos de RNA's, cada uma com características próprias para melhor se adaptar na resolução dos problemas. Entre as RNA's, as Redes Perceptron de Múltiplas Camadas - *Multilayer Perceptron* (MLP) e as Redes de Funções de Base Radiais - *Radial Basis Function* (RBF), têm se destacado. As RNA's podem ser usadas em diversos casos de previsão e predição, que se estendem desde a caracterização de materiais como o concreto, até balanços hídricos de sistemas agrícolas (TAVARES *et al.* 2020; SANTOS & SILVA, 2020).

No estudo do concreto, por exemplo, a implementação das RNA's pode contribuir de forma significativa para o estudo da determinação da resistência à compressão em várias idades de cura (TAVARES *et al.* 2020). Isso porque o concreto é um material heterogêneo e sua descrição matemática não se apresenta de forma linear. Além disso, suas propriedades dependem de diversos fatores, que incluem a padronização dos métodos de dosagem, tipo de cimento, características dos agregados utilizados, aditivos que melhoram suas propriedades no estado fresco, grau de porosidade e a forma de realização do ensaio para a determinação da resistência à compressão (CARVALHO e FILHO, 2014; TUTIKIAN; HELENE, 2011).

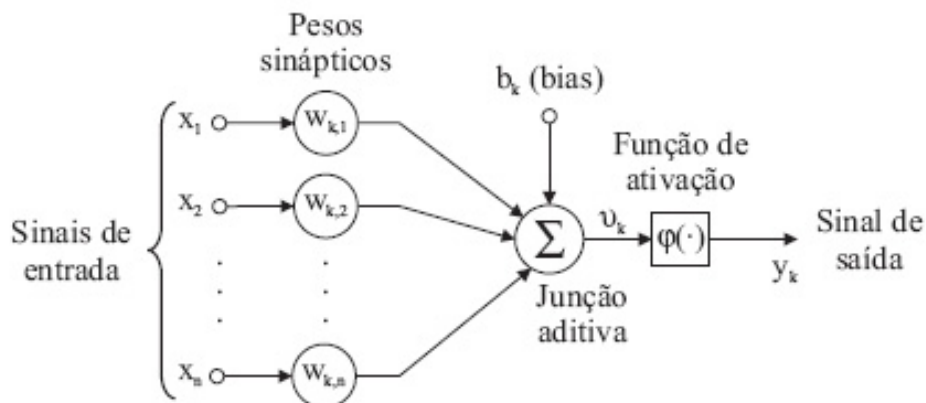
Alguns problemas podem ocorrer em um concreto mal dosado, tais como, erosão, aberturas de fissuras, descoloração, lixiviação e durabilidade, todos decorrentes da falta de resistência desejada (NEVILLE e BROOKS, 2010). Portanto, o uso das Redes Neurais Artificiais no processo de previsão da resistência à compressão tem se apresentado como uma possível ferramenta para o controle tecnológico do concreto.

Com base nos aspectos abordado acima, o objetivo desse estudo foi aplicar RNA's do tipo RBF e MLP, treinadas e validadas com aprendizado supervisionado, para a previsão da resistência à compressão. Essa análise foi possível a partir dos dados de entrada, que representam os materiais constituintes do concreto em diferentes idades de cura. Os resultados preliminares desse estudo sugerem a possibilidade das RNA's para o controle tecnológico do concreto, o qual se apresenta como o material de maior consumo na construção civil.

2 REDES NEURAIIS ARTIFICIAIS

As Redes Neurais Artificiais (RNAs) são modelos matemáticos que simulam a estrutura neural humana. O sistema de camada única é bem simples, o qual é constituído por nodos (X_1, X_2, \dots, X_n), também chamados de unidades de processamento, que calculam as funções matemáticas. Essas funções são associadas a um peso ($W_{k,1}, W_{k,2}, \dots, W_{k,n}$), que por meio da sua soma ponderada resulta um nível de atividade, e caso exceda o seu limite (*threshold*), resulta uma saída. As RNAs passam por uma etapa de aprendizagem, na qual parte das informações são lançadas na rede, para que a mesma automaticamente entenda as suas principais características. Esses atributos são utilizados como parâmetros no processo de aprendizagem, fornecendo resultados para os problemas. Esse é o maior diferencial de uma RNA, que é sua capacidade aprender e de generalizar, sem apenas vincular entrada e saída, e sim gerar informações que não foram apresentadas explicitamente na fase de treinamento, reconhecendo padrões que não estavam presentes no processo de aprendizagem (BRAGA, CARVALHO, LUDEMIR, 2000). A Figura 1 mostra o modelo de um neurônio artificial para uma rede neural de camada única.

Figura 1 – Modelo não-linear de um neurônio



Fonte: Haykin (2001)

A classificação da rede varia conforme a sua arquitetura, já que está relacionada com o algoritmo de aprendizagem utilizado no treinamento, também chamado de algoritmo estruturado. Dependendo da arquitetura, pode ser utilizado diferentes tipos de aprendizado. As três arquiteturas mais conhecidas são as redes de camada única, onde há uma entrada de nós que fornece uma saída de neurônios; redes de múltiplas camadas, que se diferencia pela presença de camadas ocultas, e tem como finalidade interferir entre a entrada e saída de forma significativa; e redes recorrentes, que se caracteriza por ter no mínimo um laço de realimentação (KAYKIN, 2001).

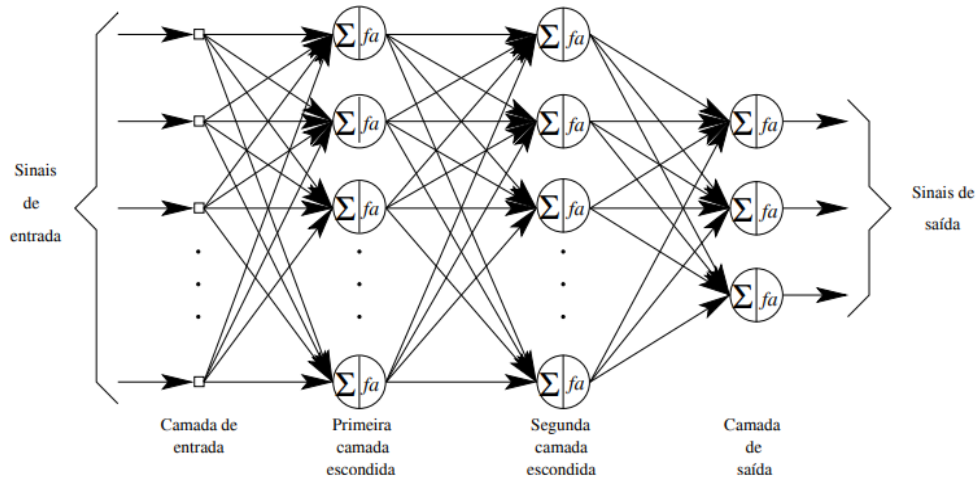
A aprendizagem constitui-se em um processo de ajustes de pesos no ambiente que está sendo operado, adquirindo no fim o conhecimento da rede, melhorando o seu desempenho. (BRAGA, CARVALHO, LUDEMIR, 2000). Há pelo menos três tipos de aprendizado que se sobressaem, sendo eles o supervisionado, em que os parâmetros de entrada e saídas são conhecidos e estabelecidos utilizando a diminuição do erro; o não-supervisionado, na qual a rede escolhe os parâmetros sem conhecer a saída desejada; e o aprendizado por reforço, em que existe uma função heurística para classificar a qualidade da saída de acordo com uma determinada entrada (SIMÕES, 2006).

Sabe-se que as RNAs podem ser organizadas de várias formas, como a quantidade de camadas, o número de neurônios de cada camada, e como essa ligação é realizada. Tudo dependerá do tipo de problema proposto. Quando existe uma situação de um problema de classificação, por exemplo, sempre são utilizadas no mínimo três camadas: a primeira (entrada), a última (saída) e as intermediárias (ocultas). Em muitos casos, a rede deverá ser treinada com um processo de tentativa e erro, de forma que se a mesma não apresentar uma performance desejada, deverão ser alterados os seus parâmetros, tais como a taxa de aprendizagem, número de neurônios e camadas, funções e conexões, entre outros (ARTERO, A., 2009).

2.1 PERCEPTRONS DE MÚLTIPLAS CAMADAS (MLP)

Quando surgem problemas com um grau de dificuldade maior, geralmente são aplicados Perceptrons de Múltiplas Camadas (MLP) com treinamento supervisionado (HAYKIN, 2001). Conforme Nied (2007), as redes MLP tratam de dados que não são linearmente separáveis, tornando necessário acrescentar camadas ocultas, diferente do algoritmo de camada única de Rosenblatt. Cybenko (*apud* Nied, 2007) ainda afirma que as camadas intermediárias alimentam a aproximação de funções contínuas da RNA ao utilizar uma função do tipo sigmoidal. A Figura 2 mostra uma rede MLP com duas camadas escondidas.

Figura 2 – Rede MLP com duas camadas escondidas



Fonte: Nied (2007)


O *back-propagation* (BP) e o *Levenberg-Marquardt* (LM) são os algoritmos mais conhecidos da rede MLP. O BP, também conhecido como algoritmo de retropropagação de erro, é fundado através da regra de aprendizagem por correção de erro, dividindo-se em duas etapas. Na fase *forward*, que significa um passo para frente, consiste em um vetor de entrada aplicado nos pesos da rede e o seu efeito é gradativo, propagando nas suas camadas ocultas. As saídas são os resultados da rede e durante esse processo os pesos sinápticos são fixos. A diferença entre a saída desejada e a obtida é conhecida como sinal de erro. Na fase *backward*, que quer dizer um passo para trás, é onde ocorre o ajuste dos pesos com o objetivo de que na saída se obtenha uma resposta mais próxima da desejada (HAYKIN, 2001).

O algoritmo LM é um processo melhorado do BP, pois é mais acelerado e possui melhores resultados que o gradiente descendente. Nesse caso, utiliza-se dados da segunda derivada da função de erro, podendo ser classificado como algoritmo de segunda ordem (FIORIN, 2011).

2.2 REDES DE FUNÇÃO DE BASE RADIAL (RBF)

Nas redes com mais de uma camada, é utilizada como função de ativação, o produto do vetor de entrada pelo o seu peso. Entretanto, em algumas dessas redes, a função só poderá ser ativada por meio das distâncias entre as entradas e o peso. As Funções de Base Radiais (RBF) são classificadas como uma dessas redes. Portanto, são utilizadas funções de base radiais nas camadas intermediárias, enquanto nas redes MLP podem utilizar funções de base sigmodais (BRAGA, CARVALHO, LUDEMIR, 2000). A arquitetura dessa rede está representada na Figura 3.

Figura 3 – Rede RBF com uma camada intermediária.



Fonte: Braga, Carvalho, Ludemir (2000)

Os valores das funções de uma RBF diminuem ou aumentam de acordo com a distância do seu centro (*cluster*). Nas Equações 1, 2 e 3 estão apresentadas algumas funções de uma RBF (adaptado de HAYKIN, 2001):

$$\text{Função gaussiana:} \quad f(u) = \exp\left(-\frac{v^2}{2\sigma^2}\right) \quad (1)$$

$$\text{Função multiquadrática:} \quad f(u) = \sqrt{v^2 + \sigma^2} \quad (2)$$

$$\text{Função thin-plate-spline:} \quad f(u) = v^2 \log(v) \quad (3)$$

3 MATERIAIS E MÉTODOS

3.1 BANCO DE DADOS

Os atributos adotados para o desenvolvimento desse trabalho foram retirados da *UC Irvine Machine Learning Repository*, que possui um vasto banco de dados disponíveis para uso. O banco de dados utilizado possui como título *Concrete Compressive Stength Data Set*, o qual foi fornecido pelo doador I-Cheng Yeh, do Departamento de Gerenciamento de Informações da Universidade de Chung-Hua, Hsin, em Taiwan.

No banco de dados utilizado há 1030 instâncias, ou seja, situações distintas com 9 atributos, sendo 8 variáveis de entrada e 1 variável de saída. É importante ressaltar que a estimativa da resistência à compressão do concreto é um problema de regressão. Na Tabela 1 está especificado cada atributo relacionado:

Tabela 1 – Atributos de entrada e saída

Entrada		
	Atributo	Unidade de medida
1	Cimento	kg em 1 m ³ de mistura
2	Escória de alto forno	kg em 1 m ³ de mistura
3	Cinzas Volantes	kg em 1 m ³ de mistura
4	Água	kg em 1 m ³ de mistura
5	Superplastificante	kg em 1 m ³ de mistura
6	Agregado graúdo	kg em 1 m ³ de mistura
7	Agregado miúdo	kg em 1 m ³ de mistura
8	Idade	Dia
Saída		
	Atributo	Unidade de medida
9	Resistência à compressão	Megapascal (MPa)

3.2 PARÂMETROS ADOTADOS NO TREINAMENTO DAS REDES

Para a criação da MLP foi utilizado o *software* Matlab R2018a. Os padrões de treinamento adotados admitiram entradas que variavam de x_1 a x_8 e a saída (Y_d) normalizadas. Na equação 3, demonstra como as variáveis normalizadas foram encontradas:

$$X_{norm} = \frac{(x - x_{min})}{(x_{máx} - x_{min})} \quad (1)$$

Em que, X_{norm} corresponde a variável normalizada encontrada, x , a variável que se deseja normalizar, x_{min} , o valor mínimo e $x_{máx}$, o valor máximo. Essa normalização foi empregada em todas as entradas e saídas desejadas no treinamento e na análise e validação dos dados.

Na fase de treinamento foram definidas as quantidades de neurônios e de camadas escondidas, além do tipo de saída desejada, de maneira aleatória. Os algoritmos de treinamento *back-propagation* e *Levenberg-Marquardt* foram testados com o objetivo de entender o comportamento de ambas e determinar qual possui o menor erro e tempo de treinamento para o banco de dados adotado. No treinamento foram utilizadas 879 linhas da matriz e 151 para a validação. O número máximo de ciclos foi igual a 1000 e um erro mínimo desejado para a rede foi de 0.001, tendendo a zero.

Na RBF também foi utilizado o *software* Matlab R2018a. Foram adotados os mesmos padrões de entrada e saída para treinamento e validação, e o erro mínimo desejado foi de 0.001. Para determinar a melhor convergência foram definidos um número máximo de neurônios que variava entre 30 a 100, pois se trata de um algoritmo de interpolação incremental, e um *spread* (largura da curva gaussiana) de

0 a 1. Durante o treinamento foi analisado o comportamento da rede de acordo com essas variações de parâmetros.

4 RESULTADOS E DISCUSSÕES

4.1 MLP

A rede MLP foi treinada utilizando de 2 a 8 camadas ocultas, e com um número de neurônios que variava de 2 a 9 em cada camada, inicialmente utilizando o algoritmo do gradiente descendente (BP) com taxa de aprendizado adaptativa. Todos os testes realizados não apresentaram uma boa convergência. Embora tenha sido aumentada a quantidade de camadas e de neurônios, o erro sempre tendeu a aumentar. Portanto, foi desconsiderado o BP nessa etapa do estudo.

Ao utilizar o algoritmo LM, foi identificado no primeiro treinamento que o erro já era menor que o BP. Assim, foram variados o número de neurônios e de camadas intermediárias com o objetivo de minimizar o erro. A arquitetura final utilizada consistiu em quatro camadas intermediárias, sendo a primeira camada com cinco neurônios e as demais com três cada. A função de ativação foi do tipo sigmoideal e a saída do tipo linear. Não foi encontrada nenhuma relação entre aumento de neurônios e as camadas com a aproximação do erro.

Desse modo, confirmou-se através dessa variação de algoritmo o que já havia sido afirmado por Hagan e Menhaj (*apud* SILVA, ALMEIDA, YAMAKAMI, 2012), que constataram para o LM os melhores resultados e com maior rapidez do que o BP.

Na Figura 4, está apresentada a resistência à compressão em Mega Pascal (MPa), obtida e desejada para 151 amostras. Na Figura 5 está apresentada a dispersão de dados do treinamento com uma correlação de 96,774%:

Figura 4 – Dados de validação da rede MLP com algoritmo *Levenberg-Marquardt*

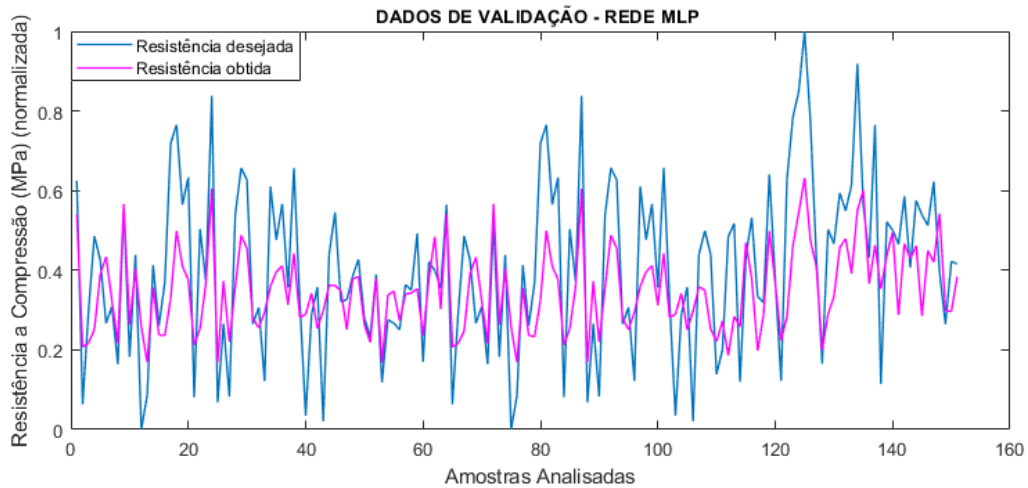



Figura 5 – Dispersão de dados do treinamento do algoritmo *Levenberg-Marquardt*



Na Tabela 2, é apresentado o tempo de treinamento em segundos para a rede MLP e o menor erro de validação encontrado em vinte tentativas com a mesma topologia de rede.

Tabela 2 – Melhor resultado do treinamento MLP em vinte execuções


MLP – Algoritmo LM	
Tempo de Treinamento (s)	7.2188
MSE Validação	0.0256

4.2 RBF

A RBF foi treinada variando arbitrariamente o seu *spread* e o número máximo de neurônios. O melhor resultado encontrado foi com um *spread* de 0.5 (50%), que corresponde à largura da curva gaussiana, utilizando uma variação de 0 a 1; e 70 neurônios, variando empiricamente de 30 a 100. Os

valores foram definidos e alterados conforme evolução do erro, não sendo identificada nenhuma relação de melhor desempenho com o aumento dessas duas variáveis. Observa-se na Figura 6 que a resistência à compressão do concreto, obtida e desejada em 151 amostras analisadas na rede RBF, possui uma proximidade maior do que àquela analisada na rede MLP, a qual foi apresentada anteriormente na Figura 4.

Figura 6 – Dados de validação da rede RBF



Na Tabela 3 são apresentados os valores da interpolação incremental obtidos com a variação de 5 em 5 neurônios durante o treinamento da rede RBF.

Tabela 3 – Interpolação Incremental encontrado na variação de 0 a 70 neurônios durante o treinamento

Neurônios	MSE
0	0.0462528
5	0.0177958
10	0.0130947
15	0.00756469
20	0.00715351
25	0.00690071
30	0.00643931
35	0.00621766
40	0.00597333
45	0.00573233
50	0.0055389
55	0.00530452

60	0.00517134
65	0.00502973
70	0.00484031

Na Tabela 4 está apresentado o tempo de treinamento (em segundos) para a rede RBF e o menor erro de validação encontrado em vinte execuções.

Tabela 4 – Melhor resultado do treinamento RBF em vinte execuções

RBF	
Tempo de Treinamento (s)	4.3281
MSE Validação	0.0129

Ao comparar o treinamento das duas redes, a RBF apresentou um desempenho melhor que a MLP, tanto no tempo de treinamento, que corresponde à aproximadamente 60% do tempo gasto na MLP, como no erro (MSE), que é cerca de 50% menor.

5 CONCLUSÕES

Os resultados preliminares desse estudo permitiram concluir que a implementação de RNAs são capazes de realizar uma excelente estimativa da resistência à compressão do concreto simples obtido com diferentes traços. Esse fato foi observado, tanto com o uso das redes MLP com algoritmo LM, como também com o uso da rede RBF. As duas redes utilizadas apresentaram um bom tempo de convergência, que foram de 7.2188 e 4.7812 segundos, respectivamente. Além disso, os erros de aproximadamente 0.0256 para o algoritmo LM e 0.0129 a RBF, foram bem baixos, indicando a RBF apresenta um melhor desempenho.

Conclui-se também que as aplicações das RNAs podem contribuir de forma significativa com o controle tecnológico do concreto, sendo possível seu em outros materiais aplicados na construção civil.

REFERÊNCIAS

- ARTERO, A. O. **Inteligência artificial: teórica e prática**. São Paulo: Editora Livraria da Física, 2009.
- BRAGA, A.P; CARVALHO, A. C. P. L. F; LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000.
- CARVALHO, R. C.; FILHO, J. R. F. **Cálculo e detalhamento de estruturas usuais de concreto armado: segundo a NBR 6118:2014**. 4 ed. São Carlos: EdUFSCar, 2014. 415 p.
- FIORIN, D.V. et al. **Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares**. Revista Brasileira de Ensino de Física, v. 33, n. 1, 1309 (2011). 394 p.
- HAYKIN, S. **Redes neurais: princípios e prática**. trad. Paulo Martins Engel. 2 ed. Porto Alegre: Bookman, 2001.
- NEVILLE, A. M.; BROOKS, J. J. **Tecnologia do concreto**. 2 ed. Porto Alegre: Bookman Editora LTDA, 2010.
- NIED, A. **Treinamento de redes neurais artificiais baseado em sistemas de estrutura variável com taxa de aprendizado adaptativa**. 2007. Tese (Doutorado em Engenharia Elétrica). Programa de pós-graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, Belo Horizonte, 2007.
- ROSA, J. L. G. **Fundamentos da inteligência artificial**. Rio de Janeiro: LTC, 2011.
- SIMÕES, A. S. **Aprendizado não-supervisionado em redes neurais pulsadas de base radial**. 2006. Tese (Doutorado em Engenharia Elétrica). Escola Politécnica da Universidade de São Paulo. Universidade de São Paulo, São Paulo, 2006.
- TAVARES, D. S. et al. (2020). **Use of artificial neural networks to predict concrete compression strength**. *Braz. J. of Develop.*, Curitiba, v.6, n.7, p. 42185-42826, jul. 2020.
- TUTIKIAN, B. F.; HELENE, P. **Concreto: Ciência e Tecnologia**. Dosagem dos concretos de cimento Portland. cap. 12. São Paulo: IBRACON, 2011.
- UCI. Machine Learning Repository. **Concrete Compressive Strength Data Set**. Disponível em: <<https://archive.ics.uci.edu/ml/datasets/concrete+compressive+strength>>. Acesso em: 01 nov. 2019.