

**Universidade de Brasília - UnB
Faculdade UnB Gama - FGA
Curso de Engenharia Eletrônica**

**Redes Neurais Artificiais no Reconhecimento e
Classificação de Padrões de Calcificações Mamárias em
Imagens de Mamografia**

**Autora: Stella Ferrari Alberto Lima
Orientadora: Dra. Lourdes Mattos Brasil**

Brasília, DF 2017



STELLA FERRARI ALBERTO LIMA

**Redes Neurais Artificiais no Reconhecimento e Classificação de Padrões de
Calcificações Mamárias em Imagens de Mamografia**

Monografia submetida ao curso de graduação em Engenharia Eletrônica da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em Engenharia Eletrônica.

Orientadora: Profa. Dra. Lourdes Mattos
Brasil

**Brasília, DF
2017**

AGRADECIMENTOS

A minha orientadora Profa. Dra. Lourdes Mattos Brasil por toda atenção, apoio, aprendizado e orientações ao decorrer da realização desse projeto.

Agradeço a toda minha família, principalmente à minha mãe, Nilcéia, por todo o apoio, incentivo e amor incondicional ao longo de toda minha vida.

Agradeço os membros do laboratório LIS pelo apoio e contribuição para o desenvolvimento deste projeto.

Agradeço ao meu namorado e todos meus amigos pela compreensão e auxílio em toda essa trajetória.

Agradeço a todas as outras pessoas que de alguma forma contribuíram na concretização desse projeto.

RESUMO

O câncer de mama é um dos mais incidentes no mundo e, apesar de sua alta taxa de cura, possui um processo complexo de diagnóstico. Por esse motivo, diversas técnicas vêm sendo desenvolvidas para possibilitar o diagnóstico precoce desse tipo de câncer. A alta complexidade da interpretação de exames mamográficos tem motivado a criação de Sistemas de Apoio ao Diagnóstico (SAD), que servem como uma segunda opinião para o profissional. Nesse contexto, essa pesquisa apresenta o desenvolvimento de uma metodologia para o reconhecimento e classificação automática de calcificações em imagens de mamografia para atuar como um SAD. Foram disponibilizadas para o estudo 70 imagens mamográficas, classificadas na categoria 4 pelo *Breast Imaging-Reporting and Data System* (B-IRADS). Com o objetivo de assegurar a qualidade do treinamento do sistema, o grupo inicial de 70 imagens foi aumentado artificialmente por meio de manipulações computacionais, sendo 140 o número final de imagens utilizadas. Em seguida, as imagens foram submetidas a técnicas de Processamento Digital de Imagens (PDI), afim de melhorar a qualidade e facilitar a extração de informações morfológicas das calcificações. Essas imagens foram utilizadas como entrada da Rede Neural Artificial (RNA) do tipo *Multilayer Perceptron* (MLP), que realizou o reconhecimento e a classificação dos achados. Para garantir sua capacidade de generalização, a RNA foi testada com imagens desconhecidas pelo sistema. Nesse caso, a acurácia apresentada pelo sistema foi de 61,9%.

Palavras-chave: Câncer de Mama, Sistemas de Apoio ao Diagnóstico, B-IRADS, Mamografia, Processamento Digital de Imagens, Redes Neurais Artificiais.

ABSTRACT

Breast cancer is one of the most frequent in the world, and despite its high cure rate, it has a complex diagnostic process. For this reason, several techniques have been developed to allow the early diagnosis of this type of cancer. The high complexity of the interpretation of mammographic exams has motivated the creation of Computer-Aided Diagnosis (CAD), which serve as a second opinion for the professional. In this context, this research presents the development of a methodology for the automatic recognition and classification of calcifications in mammography images to act as a CAD. To develop this study, 70 mammographic images, classified in category 4 by the Breast Imaging-Reporting and Data System (B-IRADS), were made available. In order to ensure the quality of system training, the initial group of 70 images was artificially increased by means of computational manipulations, being 140 the final number of images used. The images were then submitted to Digital Image Processing (DIP) techniques, in order to improve the quality and facilitate the extraction of morphological information from calcifications. These images were used as an input to the Multilayer Perceptron (MLP) type Artificial Neural Network (ANN), which performed the recognition and classification of the findings. To ensure its generalization capacity, the RNA was tested with images unknown to the system. In this case, the system accuracy was 61,9%.

Key words: Breast Cancer, Computer-Aided Diagnosis, BI-RADS, Mammography, Digital Image Processing, Artificial Neural Networks.

SUMÁRIO

1.	INTRODUÇÃO	11
1.1	OBJETIVO DO ESTUDO.....	13
1.2	TRABALHOS CORRELATOS	14
2.	CÂNCER DE MAMA.....	16
2.1	CALCIFICAÇÕES MAMÁRIAS.....	17
2.2	MAMOGRAFIA.....	18
2.3	CLASSIFICAÇÃO BI-RADS	19
3.	REDES NEURAIS ARTIFICIAIS.....	20
3.1	FUNÇÕES DE ATIVAÇÃO	21
3.2	<i>MULTILAYER PERCEPTRON</i>	22
3.3	PARADIGMAS DE APRENDIZAGEM	23
3.4	ALGORITMO DE APRENDIZAGEM <i>BACKPROPAGATION</i>	24
3.5	REGRA DELTA	25
3.6	REGRA DELTA GENERALIZADA.....	26
3.7	<i>CROSS-VALIDATION</i>	27
4.	PROCESSAMENTO DE IMAGENS.....	28
4.1	SEGMENTAÇÃO.....	28
4.2	EQUALIZAÇÃO DE HISTOGRAMA.....	29
4.3	OPERADORES MORFOLÓGICOS.....	30
5.	METODOLOGIA.....	30
5.1	COLETA DE DADOS.....	31
5.2	PROCESSAMENTO DE IMAGENS.....	32
5.3	SISTEMA COMPUTACIONAL.....	32
5.4	TREINAMENTO. VALIDAÇÃO E TESTE.....	33
6.	RESULTADOS E DISCUSSÕES.....	34
6.1	RESULTADOS INICIAIS.....	34
6.2	BANCO DE DADOS.....	37
6.3	PROCESSAMENTO DE IMAGENS.....	37
6.4	SISTEMA COMPUTACIONAL.....	39
6.5	TREINAMENTO. VALIDAÇÃO E TESTE.....	41
7.	CONCLUSÕES E TRABALHOS FUTUROS.....	42
	REFERÊNCIAS.....	44

LISTA DE ILUSTRAÇÕES

Figura 1. Demarcações de áreas consideradas malignas pelo sistema EIR em mamografia.....	15
Figura 2.Exemplos dos dois tipos de mamografia: (A) Mamografia Tradicional (Filme-Écran) e (B) Mamografia Digital.....	19
Figura 3. Arquitetura básica de um neurônio artificial.....	21
Figura 4. Arquitetura básica de uma MLP.....	22
Figura 5. Fluxo de informação do algoritmo <i>Backpropagation</i>	25
Figura 6. Etapas de desenvolvimento do SAD.....	31
Figura 7. Treinamento do problema XOR para a função de ativação Sigmoidal.....	35
Figura 8. Treinamento do problema XOR para a função de ativação Tangente Hiperbólica.....	36
Figura 9. Resultado do processo de rotação: (a) Imagem Original, (b) Imagem Rotacionada.....	37
Figura 10. Resultado da etapa de PDI para cada técnica utilizada: (a) Imagem original; (b) Segmentação com limiar adaptativo; (c) Equalização de histograma seguido de segmentação com limiar adaptativo; (d) Segmentação com limiar adaptativo seguido de fechamento.....	38
Figura 11. Valores definidos para cada parâmetro pela ferramenta <i>Grid Search</i>	40

LISTA DE TABELAS

Tabela 1. Teste de parâmetros da RNA para a função de ativação Sigmoidal.....	35
Tabela 2. Teste de parâmetros da RNA para a função de ativação Tangente Hiperbólica.	35
Tabela 3. Valores dos parâmetros fornecidos pela ferramenta <i>Grid Search</i>	40
Tabela 4. Acurácia alcançada pela RNA para os conjuntos de validação.....	41
Tabela 5. Acurácia alcançada pela RNA para os conjuntos de teste.....	41

LISTA DE SIGLAS

BI-RADS - *Breast Imaging Reporting and Data System*

FGA - Faculdade Gama

FP – Falso Positivo

IA - Inteligência Artificial

INCA - Instituto Nacional de Câncer

MLP – *Multilayer Perceptron*

PDI – Processamento Digital de Imagens

ReLU - *Rectified Linear Unit*

RNA - Redes Neurais Artificiais

ROIs - Regiões de Interesse

SAD - Sistemas de Apoio ao Diagnóstico

UnB -Universidade de Brasília

VP – Verdadeiro Positivo

LISTA DE SÍMBOLOS

w_i	Peso sináptico do neurônio i
x_j	Valor de entrada do neurônio j
d_j	Valor de saída desejado da RNA
y_j	Valor de saída obtido da RNA
b	Bias
β	<i>Momentum</i>
f	Função de ativação
f'	Derivada da função de ativação
α	Taxa de aprendizagem
S_k	Função distribuição acumulada

1. INTRODUÇÃO

O câncer de mama é uma das doenças mais temidas por conta de sua alta frequência e taxa de mortalidade em todo o mundo (TAHMOUSH, 2007). Esse é o câncer mais comum entre as mulheres, sendo responsável por aproximadamente 28% dos novos casos a cada ano. Segundo o INCA (Instituto Nacional de Câncer), o número de mortes em 2013 foi de 14.388, sendo 181 homens e 14.206 mulheres, só no Brasil. A estimativa de novos casos para 2016 foi de 57.960 (INCA, 2016). Apesar de ser um dos tipos de cânceres que possui as maiores possibilidades de cura, é ainda considerado uma doença complexa em nível genético. Alguns fatores podem influenciar os índices de cura da doença, como o estágio em que a doença se encontra, o tipo de tumor e o tempo levado para detecção. Atualmente, existe uma gama de ferramentas que contribuem para o desenvolvimento de metodologias de análise, diagnóstico precoce de tumores, e treinamento de procedimentos para o tratamento (RINGBORG et al., 2003).

Técnicas de rastreamento de tumores proporcionam o diagnóstico e o tratamento precoce. Esses são fatores muito importantes para maior sobrevivência das pacientes, além de possibilitar tratamentos menos agressivos (MARCOMINI, 2013). A mamografia, apesar de sua baixa especificidade, apresenta alta sensibilidade e é apontada como o método mais eficiente na detecção precoce do câncer de mama (LOUVEIRA ET AL., 2003). Segundo Giger (2000), a identificação de anomalias em imagens médicas é um procedimento susceptível a erros, até para radiologistas qualificados, devido a fatores como o grau de subjetividade na delimitação de fronteiras e na definição de características benignas e malignas, além da presença de ruídos, que dificultam ainda mais o diagnóstico. Cerca de 10% a 30% das mulheres que apresentaram câncer de mama, ao realizarem a mamografia, obtiveram resultados negativos, o que demonstra o resultado da má interpretação dos exames. Com o objetivo de reduzir esses erros e auxiliar na detecção precoce da doença, o desenvolvimento de sistemas computacionais vem sendo visto como uma ferramenta alternativa no auxílio ao diagnóstico (STAVROS, 2009).

Sistemas computacionais utilizados como ferramenta de auxílio à tomada de decisões vêm ganhando espaço em diversas áreas, mas tem a medicina como uma de suas principais áreas de aplicação. Existem diversas atividades na área médica que

fazem uso desses sistemas, sendo os Sistemas de Apoio ao Diagnóstico (SAD) um dos mais marcantes. Esses têm como propósito auxiliar o processo de tomada de decisões, servindo como uma segunda opinião, assim assistindo o profissional da área. Diagnósticos médicos são baseados na investigação de dados e informações coletadas pelo profissional em diferentes fontes, incluindo a experiência do médico em outros diagnósticos do mesmo tipo. A gama desses dados, informações e conhecimentos vem se tornando cada vez maior, assim, para que médico desempenhe competidamente suas funções deve sempre se renovar diante as novidades que surgem (AMBRÓSIO, 2002).

Sendo assim, a função básica dos SAD é apoiar o profissional em diversos aspectos, principalmente no de memorização e processamento da grande quantidade de informações envolvidas na etapa de diagnóstico. Geralmente desenvolvidos utilizando técnicas de Inteligência Artificial (IA), tentam simular o raciocínio humano através de análises de decisões, com a habilidade de construir um raciocínio automático e desempenhar inferências lógicas como induções e deduções (COEIRA, 1996).

Dentro do vasto campo de estudo da IA existem diversas teorias, sendo uma delas a de Redes Neurais Artificiais (RNA). A teoria das RNA vem se estabelecendo como uma nova e eficaz ferramenta para tratar com a classe dos chamados problemas complexos, nos quais grandes quantidades de dados são trabalhados e analisados. As RNA são identificadas como uma especialidade de IA, assim como uma classe de modelos matemáticos para classificação e reconhecimento de padrões, e até mesmo como uma categoria de paradigmas da ciência da cognição. Apesar de todas estas definições serem adequadas a RNA, resumi-las em somente algum destes conceitos seria limitante. Atualmente, estabelecem uma teoria para o estudo de fenômenos complexos (KOVÁCS, 2006).

Dentro do ramo das RNA são tratados diversos modelos, cada um sendo mais adequado para determinada aplicação. Para um sistema que deve resolver problemas não lineares, utiliza-se RNA do tipo *MultiLayer Perceptron* (MLP). A topologia desse tipo de RNA fundamenta-se em unidades sensoriais que compõem as camadas do sistema, sendo elas: camada de entrada, camadas intermediárias ocultas e camada de saída (SILVA et al., 2010). Para desempenhar suas funções adequadamente, uma RNA passa por um processo de aprendizagem. Esse processo, na MLP, se dá através de um processo supervisionado, ou seja, são disponibilizadas as entradas e

respectivas saídas desejadas, constituindo assim uma amostra de treinamento (MARCOMINI, 2013).

Em vista disso, o desenvolvimento, validação e análise da RNA do tipo MLP será realizada na linguagem de programação *Python*. Segundo Raschka (2015), a linguagem de programação *Python* é uma das mais utilizadas do grupo das Ciências de Dados e dispõe de uma grande quantidade de bibliotecas elaboradas por sua comunidade. Apesar de possuir algumas desvantagens para atividades de computação intensiva por se tratar de uma linguagem interpretada, sendo inferior às linguagens de programação de baixo nível, a linguagem *Python* desfruta de bibliotecas de extensão como *NumPy* e *SciPy*, que foram elaboradas para operações rápidas e vetorizadas em *arrays* multidimensionais (RASCHKA, 2015).

Assim, esse trabalho apresentará o desenvolvimento de uma RNA do tipo MLP que seja capaz de identificar, por meio de processamento de imagens e reconhecimento de padrões, microcalcificações mamárias que apresentem malignidade em imagens de mamografia.

1.1 OBJETIVO DO ESTUDO

Este estudo objetiva desenvolver uma RNA do tipo MLP para localização e classificação de microcalcificações mamárias em de zonas de interesse de mamografias direcionada para atuar como um SAD.

Os objetivos específicos são:

- Estudar as calcificações mamárias;
- Coletar dados de imagens de mamografias com calcificações suspeitas de malignidade;
- Desenvolver uma RNA para a identificação de microcalcificações mamárias em imagens de mamografia;
- Testar, treinar e validar a RNA afim de avaliar seus resultados e sua capacidade de generalização para trabalhar como um SAD.

1.2 TRABALHOS CORRELATOS

O trabalho de Marcomini, K. D. (2013) utiliza RNA na classificação de nódulos em imagens de ultrassonografia de mama. Na realização desse estudo as imagens foram pré-processadas e diversas técnicas de segmentação foram aplicadas com o objetivo de definir a mais apropriada. Com a delimitação do objeto, foram estabelecidas características mais relevantes para a descrição morfológica do achado. Os dados obtidos foram utilizados como a entrada da RNA do tipo MLP. A acurácia alcançada durante o treinamento foi de 94,2%. Para qualificar a generalização dos resultados obtidos foi realizada a classificação com imagens desconhecidas do sistema, nesse caso a acurácia alcançada foi de 81% (MARCOMINI, 2013).

Martins (2016) propôs o desenvolvimento de um Sistema Inteligente Para Detecção e Classificação de Calcificações em Mamografias. O objetivo deste trabalho, denominado de EIR, foi a localização, definição de características e classificação de áreas de relevância em mamografias. O grupo de treinamento do sistema foi composto por 37 imagens mamográficas, todas com suspeição de malignidade, sendo classificadas na categoria 4 pelo BI-RADS. O grupo de dados foi aumentado artificialmente, resultando em um total de 255 imagens, com o objetivo de obter um treinamento mais eficiente do sistema. O treinamento do EIR foi qualificado por meio de critérios como Acurácia, Precisão, *Recall* e *F1 Score*. O estudo atingiu como resultado final uma taxa de 99% de acurácia, 99% de precisão, 99% de sensibilidade e *F1 Score* de 0.99 (MARTINS, 2016). A Figura 1 mostra o resultado alcançado para a demarcação de áreas classificadas como malignas para o EIR.

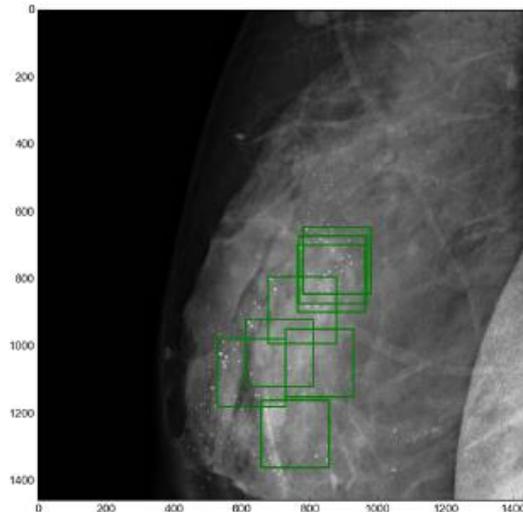


Figura 1. Demarcações de áreas consideradas malignas pelo sistema EIRem mamografia. Fonte: MARTINS (2016)

O trabalho de Ambrósio (2002) apresenta o desenvolvimento de uma RNA do tipo MLP para a aplicação em um SAD para identificação de um grupo de patologias classificadas como lesões intersticiais pulmonares. Para a realização desse estudo, dentre um universo de mais de 180 tipos de patologias pulmonares, foram definidas 9 a serem identificadas pelo sistema. O sistema foi treinado utilizando como conjunto de treinamento de imagens nas quais houve a comprovação do diagnóstico por um profissional especializado. A saída do sistema apresentou como resultado todas as 9 patologias, demonstrando a classificação de acordo com a probabilidade de ser a patologia encontrada na imagem. Para avaliar os resultados foram levadas em consideração as ocorrências em que o sistema apresentou o resultado correto entre a primeira ou segunda opção da lista de classificação (AMBRÓSIO, 2012). Em testes realizados com amostras não usadas no treinamento do sistema, os percentuais de acerto obtidos foram de 68,75% para apresentação da patologia correta na primeira possibilidade e 81,25% para apresentação da patologia correta entre as duas primeiras possibilidades.

Elpídio (2012) desenvolveu um sistema de auxílio na avaliação de calcificações mamárias por meio de técnicas de Processamento de Imagens (PDI) e IA. O objetivo desse estudo foi evidenciar as características das calcificações utilizando técnicas de PDI e utilizar uma RNA do tipo MLP para classificá-las segundo a classificação BI-RADS. Foi elaborado um sistema de Raciocínio Baseado em Casos para indicar a qual categoria BI-RADS a calcificação mamária em questão pertence. A eficiência do

sistema foi avaliada em testes com calcificações simuladas e validado com calcificações reais. Para finalidade de teste, o algoritmo *Backpropagation* foi utilizado obtendo resultados de classificação com até 98% de acerto.

2. CÂNCER DE MAMA

O câncer de mama é descrito como o crescimento desenfreado de células mamárias, resultando em um tumor com possibilidade de metástase. Este tipo de câncer se manifesta por meio de um nódulo palpável, de consistência endurecida, indolor e fixo (COSTA, 2009). Embora possua incidência elevada, sendo o câncer mais predominante no mundo atualmente, com número de 4,4 milhões de ocorrências de neoplasia maligna nos últimos 5 anos, o câncer de mama possui um bom prognóstico (GLOBOCAN, 2002).

Este tipo de câncer, em sua maioria, atinge as células dos ductos das mamas, dando origem ao Carcinoma Ductal, sendo esse o tipo de tumor mais comum. Há também os que atingem os lóbulos mamários, estes são menos frequente e recebem o nome de Carcinoma Lobular (GONDIM, 2013).

O câncer de mama tem origem genética, sendo que de 90 a 95% deles são pontuais, ou seja, ocasionados por mutações somáticas e hábitos que transcorrem durante a vida, e que entre 5% a 10% sejam hereditários, isto é, são ocasionados por conta da herança genética transmitida dos ascendentes aos descendentes (BILMORIA, 1995).

Alterações genéticas podem ocasionar um tumor, mas para que isso ocorra é necessária a contribuição de fatores promotores, o que deve ocorrer ao longo de muitos anos, até mesmo décadas (AGUILLAR et al., 2009). Estudos apontam diversos fatores que tornam mulheres mais susceptíveis ao câncer de mama. Condições como idade, parentesco em primeiro grau com pessoas que já foram acometidas pelo câncer de mama, menarca prematura, menopausa tardia, primeira gravidez depois dos 30 anos e câncer de mama precedente são fatores de alto risco para o desenvolvimento da doença (MARTINS, 2016).

Técnicas de rastreamento de tumores viabilizam o diagnóstico precoce e tratamentos menos agressivos, sendo de extrema importância para uma melhor sobrevida de pacientes (MARCOMINI, 2013). As etapas do tratamento deste câncer consistem no estudo do tumor, quantificação do seu tamanho e da sua diversidade

histopatológica. Também devem ser levados em consideração outros fatores, como os aspectos da imagem de mamografia, a situação da paciente e, até mesmo, o seu desejo de manter a mama. (CONDUTAS INCA, 2001)

2.1 CALCIFICAÇÕES MAMÁRIAS

Biópsias mamárias de pacientes que apresentaram suspeição de câncer em suas mamografias comprovaram a doença em aproximadamente 30% das ocorrências. Nos casos nos quais foram encontradas microcalcificações agrupadas nas mamografias, a ocorrência de câncer *in situ* foi de até 90% (RESENDE et al., 2017). Tendo sua importância revelada, microcalcificações passam então a ser consideradas achados mamográficos (LEBORGNE, 1951).

Calcificações são constituídas de cálcio. Esse acúmulo de cálcio é transportado do sangue até os tecidos, onde passa por transformações e termina se estabelecendo como sais de cálcio. As calcificações mamárias podem ser classificadas de duas maneiras: a primeira delas é constituída de oxalato de cálcio desidrato e apresenta condições benignas em 90% das suas ocorrências. A segunda classificação se trata daquelas resultantes do acúmulo de fosfato de cálcio em tecido necrosado e representa aproximadamente 70% dos achados (RESENDE et al., 2017).

Com aproximadamente 1 mm de diâmetro as microcalcificações mamárias podem ser identificadas pela mamografia e a partir de 1 cm é possível diagnosticá-las por meio de exame físico. Antes de atingir o tamanho mínimo para ser possível a detecção pela mamografia, o aumento da calcificação se dá de forma muito demorada, levando cerca de 10 anos para alcançar 1 mm. Porém, a partir desse ponto o desenvolvimento tumoral se dá de forma mais rápida, demorando aproximadamente 3 anos para crescer de 1 mm a 1 cm (AGUILLAR et al., 2009).

As calcificações são classificadas segundo os tipos e sua distribuição: tipos de calcificações – benignas, intermediárias e provavelmente malignas

1- Benignas

Entre as calcificações tipicamente benignas listam-se as calcificações com centros radio transparentes; calcificações vasculares, com aspecto de paralelas ou tubulares e lineares; grosseiras (Tipo “pipocas”), clássicas no fibroadenomas evoluídos; bastonetes, frequentes na mastites plasmocitária e

ectasiaductal; redondas, centro translúcidas (necrose gordurosa, ductos calcificados e fibroadenomas); casca-de-ovo, encontradas na necrose gordurosa e paredes de cistos; leite de cálcio, frequentes em cistos; calcificações distróficas, comum em mamas irradiadas ou pós trauma; calcificações de suturas, após radioterapia – lineares ou tubulares; e puntiformes, redondas ou ovais, menores que 0,5 mm.

2- Intermediárias

São calcificações amorfas, geralmente redondas ou em flocos, suficientemente pequenas ou duvidosas para que sua morfologia específica seja determinada.

3- Provavelmente malignas

Destacam-se dois tipos; as pleomórficas ou heterogêneas, que apresentam tamanho e forma irregulares, e são menores de 0,5 mm. As ramificadas são lineares, finas e irregulares, descontínuas e menores de 0,5 mm em sua extensão (CHAKRABARTI et al., 2006).

2.2 MAMOGRAFIA

A mamografia é atualmente o mais relevante método de detecção do câncer de mama precocemente, por realizar a detecção de alterações ainda não palpáveis, assim possibilitando um tratamento mais eficaz e menos destrutivo (BOYLE, 2002). É considerada a ferramenta de rastreamento mais efetiva, podendo diminuir a taxa de mortalidade da doença de 18 a 30%. O diagnóstico precoce possibilitado pela mamografia pode ampliar em até 95% as probabilidades de cura da paciente, permitindo a constatação do câncer de 3 a 4 anos antes do aparecimento dos primeiros sintomas (BORGHESAN et al., 2003).

O exame de mamografia é realizado com o mamógrafo, um equipamento emissor de ondas raio-X, no qual o paciente posiciona a mama entre suas placas e tem a mama pressionada. Trata-se de um exame desconfortável e por algumas vezes doloroso, porém a pressão sofrida pela mama diminui a sobreposição de tecidos, assim aumentando as chances de identificação de calcificações (SOUZA, 2012).

A formação das imagens provenientes dos exames de mamografia se dão de duas formas. O primeiro tipo de geração de imagens provém da mamografia tradicional e é constituído por filme-écran, o segundo tipo trata-se da mamografia digital. No caso da mamografia tradicional, que tem o filme como o meio de obtenção

da imagem, resulta em uma imagem de alta qualidade, porém há pouca possibilidade de melhorias. No caso da mamografia digital, cada procedimento realizado na imagem ocorre de maneira separada, assim cada um deles pode ser melhorado separadamente, também a imagem digital conta com a opção de processamento de imagem, diferente da primeira opção. A mamografia digital também viabiliza a associação com SAD (CHALA, 2007).

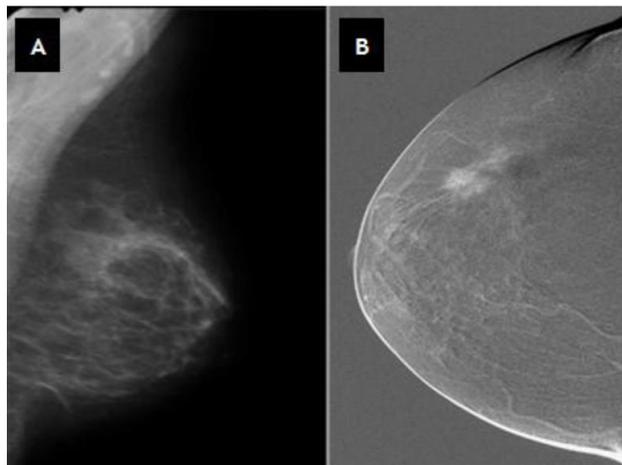


Figura 2. Exemplos dos dois tipos de mamografia: (A) Mamografia Tradicional (Filme-Écran) e (B) Mamografia Digital.

Fonte: NOGUEIRA, 2016

2.3 CLASSIFICAÇÃO BI-RADS

A classificação BI-RADS™ foi criada para realizar uma padronização de relatórios mamográficos tornando as informações mais claras. A falta de padronização pode ocasionar em relatórios imprecisos que podem causar confusões na interpretação mamografias como positivas ou negativas. O BI-RADS é vantajoso pois se trata de um modelo que antecipa o diagnóstico, além de recomendar os procedimentos a serem tomados, baseado nos achados mamográficos (VIEIRA, 2002).

O BI-RADS classifica os achados mamográficos conforme o grau de risco para câncer de mama. Essa classificação é feita em seis categorias, que são:

·Categoria 0: Nesta categoria estão inclusos os casos que necessitam de avaliação adicional. É indicada a comparação com exames anteriores ou realização de exame de imagem adicional.

Categoria 1: Nesta categoria não há nada a se comentar, não há nódulos, distorção arquitetural, calcificações suspeitas de malignidade ou assimétricas.

·Categoria 2: Achados benignos. Estão inclusos nesta categoria fibroadenomas, calcificados involuídos, múltiplas calcificações secretórias, lesões com conteúdo de gordura, tais como cistos oleosos, lipomas, galactoceles e hamartomas de densidades mistas. Todos têm aparência caracteristicamente benigna e podem ser classificados com segurança.

·Categoria 3: Achado provavelmente benigno, com menos de 2% de possibilidade de malignidade. É sugerido ao especialista um seguimento mamográfico da mama com o achado em um intervalo de tempo de 6 meses.

·Categoria 4: Nessa categoria se encaixam achados com anormalidade suspeita. Tais achados não têm uma aparência clássica de malignidade, possuem probabilidade de malignidade de 2% a 95%. Biópsia deve ser considerada.

·Categoria 5: Achados altamente sugestivos de malignidade. Lesões nessa categoria têm uma probabilidade maior que 95% de chance de ser câncer. Biópsia para comparação deve ser realizada.

Categoria 6: Aqui se encaixam achados com malignidade comprovada. A malignidade é comprovada através de biópsia do achado. Nessa categoria é indicada a conduta terapêutica adequada (MARTINS, 2016, p. 25).

3 REDES NEURAIS ARTIFICIAIS

As RNA são modelos computacionais que, por meio de paradigmas matemáticos, tentam reproduzir a estrutura neural humana, na qual a aprendizagem ocorre pela experiência. A estrutura dessa rede é formada por neurônios artificiais, que são interconectados e atuam simultaneamente. Esses neurônios, que são as unidades básicas de uma RNA, realizam operações mediante um estímulo de entrada

e transferem seus resultados aos neurônios aos quais está conectado (PERELMUTER et al., 1995).

As especificidades de uma RNA são definidas de acordo com as funções que ela terá que desempenhar e estabelecem os parâmetros da mesma, como: a quantidade e características dos neurônios, tipo de treinamento, entre outros. A sua estrutura pode ser formada por múltiplos neurônios, distribuídos em diversas camadas, as quais podem trilhar diversos padrões de conexão (AMBRÓSIO, 2002).

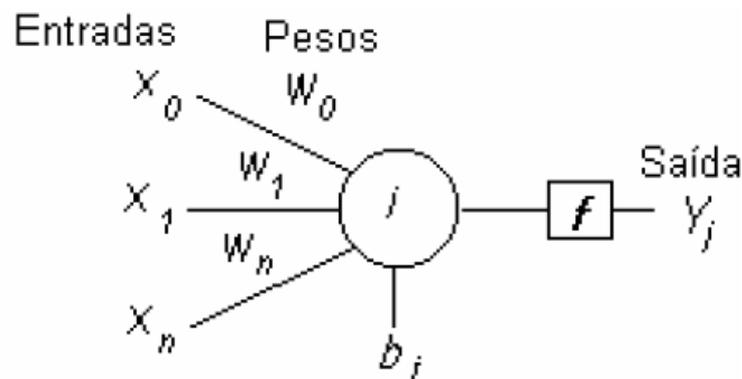


Figura 3 – Arquitetura básica de um neurônio artificial.

Fonte: AMBRÓSIO, 2002.

Na Figura 2, a variável X representa as entradas, W os pesos sinápticos, b o valor de bias, f a função de ativação e Y os valores de saída (AMBRÓSIO, 2002). A relação entre as variáveis pode ser obtida pela equação abaixo:

$$Y = f\left(\sum_{i=0}^n w_i \cdot x_i + \text{bias}\right) \quad (1)$$

3.1 FUNÇÕES DE ATIVAÇÃO

Uma função de ativação é o parâmetro de uma RNA que determina se um neurônio irá ou não repassar a informação dos estímulos que são recebidos na sua entrada para os neurônios conectados a ele. Algumas das principais funções de ativação não lineares são: Tangente Hiperbólica, *Rectified Linear Unit* (ReLU) e Sigmóide (MARTINS, 2016). As equações abaixo descrevem matematicamente cada uma delas:

$$\text{TanH}(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (2)$$

$$h\theta(x) = \frac{1}{1 + e^{-\theta x}} \quad (3)$$

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

3.2 MULTILAYER PERCEPTRON

Os neurônios artificiais que constituem uma RNA são chamadas de *Perceptrons*. Quando se tem uma arquitetura aonde mais de um *Perceptron* é distribuído em camadas, se torna possível resolver problemas não lineares. Esse tipo de organização é chamado de *Multilayer Perceptron* (MLP). Uma RNA do tipo MLP é constituída por 3 tipos de camadas: uma camada de entrada, que recebe os estímulos que serão trabalhados; camadas ocultas, que processarão os dados e uma camada de saída (HAYKIN, 2009), na Figura 4 é possível observar a estrutura básica de uma RNA do tipo MLP:

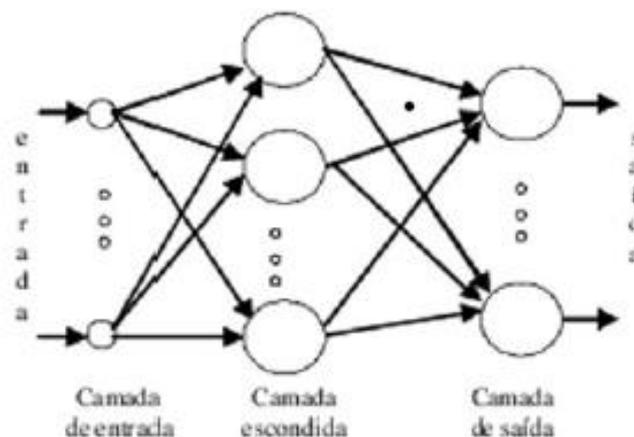


Figura 4 – Arquitetura básica de uma MLP.

Fonte: AFFONSO, 2010.

As entradas da RNA transmitem características das informações que deverão ser aprendidas. Os valores obtidos na saída, são os valores de entrada multiplicados por uma matriz de pesos (ELPÍDIO, 2012). Entre a entrada e a saída da RNA, tem-se

uma ou mais camadas intermediárias, também chamadas de camadas ocultas, as quais tem a finalidade de proporcionar uma não-linearidade para o sistema. O número de camadas ou de neurônios em cada uma das camadas afeta significativamente no desempenho da RNA, já que parâmetros como o tempo despendido para a obtenção da resposta e para o aprendizado aumenta com o aumento do número de camadas (AMBRÓSIO, 2002).

Uma RNA que não possui camadas ocultas não tem a capacidade de solucionar problemas não-lineares. Porém, escolher a quantidade de neurônios da camada oculta não é uma tarefa simples. Caso possua poucos neurônios, a RNA não é capaz de solucionar um problema proposto, caso possua neurônios em excesso, a mesma passa a funcionar como uma memória, e torna-se incapaz de realizar generalizações (AMBRÓSIO, 2002). Segundo Eberhart e Dobbins (1991), o número de neurônios na camada oculta de uma RNA pode ser estimado utilizando a Equação 5.

$$NH = NS + \sqrt{NE} \quad (5)$$

Sendo NS o número de neurônios na camada de saída e NE o número de neurônios na camada de entrada.

3.3 PARADIGMAS DE APRENDIZAGEM

Para que uma RNA aprenda, ela deve passar por um processo de treinamento, o qual pode se dar de 3 maneiras: o supervisionado, o semi-supervisionado e o não-supervisionado. No supervisionado são apresentados os valores de entrada e suas respectivas saídas desejadas, e a partir desse processo os pesos sinápticos são regulados. No treinamento semi-supervisionado são apresentadas as saídas desejadas, porém o sistema não as usa para a adaptação dos pesos e aprende por meio de respostas de sucesso e insucesso. O terceiro tipo de treinamento é o não-supervisionado no qual os valores de saída não são fornecidos e a RNA é readaptada até alcançar um resultado satisfatório (BARCA, 2005).

A técnica de treinamento usada pela RNA do tipo MLP é a aprendizagem por meio de processo supervisionado. Assim, os parâmetros são continuamente regulados pois o algoritmo de aprendizagem analisa constantemente a discrepância entre os resultados obtidos em comparação com os desejados (SILVA et al., 2010).

Após a etapa de treinamento e aprendizagem, a etapa de teste é realizada para avaliar a eficiência de generalização da RNA. Nessa etapa é verificado se a aprendizagem do sistema foi o bastante para fornecer saídas adequadas para um conjunto de valores de entrada nunca utilizados na etapa de treinamento, também chamados de conjunto de teste (ELPÍDIO, 2012).

Quando se trata de reconhecimento de padrões em imagens, os conjuntos de treinamento e teste são compostos por imagens. Para a melhoria da qualidade dessas imagens, muitas vezes é necessário que as mesmas passem por etapas de pré-processamento de imagem para que haja atenuação de ruídos e destaque de áreas de interesse. A melhoria da qualidade das imagens que formarão o conjunto de treinamento é de extrema importância, já que ele afeta diretamente a eficiência de aprendizado de uma RNA (ELPÍDIO, 2012).

3.4 ALGORITMO DE APRENDIZAGEM *BACKPROPAGATION*

Existem diversos algoritmos utilizados para realizar o treinamento de uma RNA, cada um mais adequado para determinada situação. O algoritmo mais comumente utilizado em RNA do tipo MLP é o *Backpropagation*. Esse algoritmo de aprendizado é do tipo supervisionado e é realizado em duas etapas: *forward* (para frente) e *backward* (para trás) (AFFONSO, 2010).

Na fase *forward*, os valores de entrada são aplicados aos neurônios artificiais da RNA e seu estímulo se transmite pelas camadas. Durante essa etapa os pesos sinápticos se mantêm constantes. Na última camada, um conjunto de saída é gerado, dando origem a resposta. A fase *backward* é uma etapa de ajustes. Nessa fase o valor de saída da RNA é comparado com o valor da resposta ideal, e a partir dessa comparação é gerado um erro. Este erro é transmitido no sentido contrário das conexões sinápticas (da saída para a entrada) e são regulados por uma regra de correção de erro para que a saída se aproxime do valor da resposta ideal (ELPÍDIO, 2012).

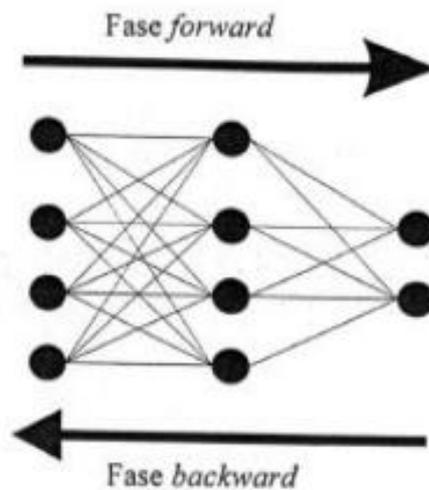


Figura 5 – Fluxo de informação do algoritmo *Backpropagation*.

Fonte: (BRAGA et al., 2000).

O treinamento de uma RNA do tipo MLP é dito satisfatório quando o erro quadrático médio entre duas épocas seguidas for menor que precisão estabelecida pelo problema. A variável época, que é a quantidade de vezes que o sistema é treinado, também é uma opção que pode funcionar como critério de parada de treinamento, quando a precisão proposta pelo problema se torna inviável de alcançar (SILVA et al., 2010).

3.5 REGRA DELTA

A Regra Delta é uma regra de aprendizagem que se baseia em adaptações dos pesos sinápticos da RNA, de acordo com os erros encontrados nos valores de saída, afim de reduzir esse erro. O erro da saída pode ser calculado subtraindo-se o resultado dele com o resultado desejado (AMBRÓSIO, 2002). Matematicamente, esse erro é definido por:

$$e_j(n) = d_j(n) - y_j(n) \quad (6)$$

Ou seja, o erro e do neurônio artificial j no instante n é igual à saída desejada (d) para esse neurônio menos sua saída realmente obtida (y).

Após o cálculo do erro, são ajustados os pesos das conexões. Segundo a regra delta, o arranjo do peso da conexão de um neurônio na camada j a um neurônio na camada k (w_{jk}), no tempo n , é calculado por (AMBRÓSIO, 2002):

$$\Delta w_{jk}(n) = \alpha * e_k(n) * x_j(n) \quad (7)$$

Onde α representa o parâmetro de aprendizagem e x_j é o valor do neurônio j .

As RNA que operam com algoritmo *Backpropagation* utilizam a regra delta generalizada, que consiste em uma variação adequada para as redes com multicamadas (COSTA, 2016).

3.6 REGRA DELTA GENERALIZADA

A regra delta generalizada minimiza o erro da RNA, ajustando seus parâmetros para que se estabilizem nos pontos mais inferiores das coordenadas da superfície do erro. Para esse ajuste é utilizada a teoria de gradiente descendente, na qual a função de ativação usada deve ser contínua, diferenciável e não-decrescente (BITENCOURT, 2015).

Nesse método, o cálculo do erro também é diferenciável. O cálculo do delta, também chamado de sensibilidade, usa a derivada das funções de ativação e a partir de seus resultados para cada neurônio é possível obter novos valores para os pesos da RNA. A sensibilidade da camada de saída pode ser calculada pela equação abaixo (VERAS, 2013):

$$\delta_j = (d_j - y_j) f'(net_j) \quad (8)$$

Onde d_j representa a saída desejada, y_j a saída realmente obtida e $f'(net_j)$ a derivada da função de ativação do neurônio de saída.

Para as demais camadas da rede multicamadas, a sensibilidade pode ser calculada por meio da equação:

$$\delta_j = f'(net_j) \sum_i \delta_i w_{i,j} \quad (9)$$

Onde $f'(net_j)$ é a derivada da função de ativação daquela camada, e $w_{i,j}$ representa o peso j do neurônio i .

Para aumentar a taxa de aprendizado e a velocidade de operação do sistema, sem causar consequências negativas, é necessário incluir o *momentum* (β). O *momentum* é uma constante que estabelece as consequências das alterações dos pesos comparados aos pesos anteriores (COSTA, 2016).

Os pesos da RNA são calculados a partir da derivada da equação de erro e o seu ajuste a cada iteração t é calculada pela equação abaixo (VERAS, 2013):

$$\Delta w_{i,j}(t + 1) = w_{i,j}(t) + \alpha \delta_j x_i + \beta (w_{i,j}(t) - w_{i,j}(t - 1)) \quad (10)$$

Onde $\Delta w_{i,j}(t + 1)$ representa o valor calculado para o i -ésimo peso do neurônio j , $w_{i,j}(t)$ representa o valor do i -ésimo peso do neurônio j no instante t , α representa a taxa de aprendizado, x_i representa o sinal do neurônio, β representa o *momentum* e $w_{i,j}(t - 1)$ representa o valor do i -ésimo peso do neurônio j no instante $t - 1$.

3.7 CROSS-VALIDATION

Ao fim do treinamento de uma RNA, é realizada a etapa de validação e teste. Os resultados obtidos nessa fase demonstram sua capacidade de generalização, comprovando a sua eficiência e justificando sua aplicabilidade para cada situação.

Existem diversos métodos utilizados para avaliar a capacidade de generalização de uma RNA do tipo MLP, sendo o *cross-validation* um dos principais deles. Esse método consiste da divisão aleatória do conjunto de amostras em 3 grupos: grupo de treinamento – que é composto de 70 a 90% das amostras – e o grupo de teste e validação, que são compostos do restante das amostras (HAYKIN, 2008). O conjunto de treinamento realiza o ajuste dos parâmetros da RNA. O conjunto de validação atua na otimização dos parâmetros durante o processo de treinamento. Já o conjunto de teste é utilizado quando a RNA estiver completamente treinada, não interferindo nas adaptações dos parâmetros e servindo apenas como avaliador do modelo final (MARTINS, 2016).

4 PROCESSAMENTO DE IMAGENS

As técnicas de PDI são baseadas em operações matemáticas e são aplicadas com o intuito de melhorar o conteúdo visual das imagens para a percepção humana e tratar seus dados para análise automática de sistemas (ELPÍDIO, 2012). A utilização de técnicas como realce, filtragem e restauração, tem como objetivo obter informações desejadas, tais como, extração de textura, detecção de bordas, além de permitir comprimir e reconstruir imagens (SILVA, 2003).

O PDI possibilita que a manipulação e a extração de informações de imagens ocorram de maneira rápida e eficiente, tornando possível a extração de dados que não poderiam ser obtidos manualmente (GOMES, 2001).

4.1 SEGMENTAÇÃO

A segmentação de imagens ocorre por meio da evidenciação de regiões ou objetos de interesse que possuam características semelhantes, como: brilho, nível de cinza ou textura (MARCOMINI, 2013). O limiar que determina o grau de divisões da imagem é determinado de acordo com o objetivo desejado, geralmente um limiar satisfatório para identificar os objetos de interesse na imagem (ELPÍDIO, 2012).

Os processos de segmentação são divididos em duas vertentes levando em consideração duas propriedades das imagens: a similaridade e a descontinuidade. A segmentação por similaridade consiste na segmentação das imagens de acordo com um padrão de similaridades entre as características de regiões. Já no processo de segmentação por descontinuidade, a segmentação ocorre com base nas mudanças bruscas do nível de luminosidade entre as regiões da imagem (PRATT, 2006).

Dentre os tipos de segmentação se destaca a técnica de segmentação com limiar adaptativo. Tal técnica realiza o cálculo da média dos níveis de cinza de cada imagem e a partir do valor obtido é definido automaticamente um valor de limiar de binarização (na qual os pixels assumem valores de 0 ou 1). Assim, é realizada uma segmentação individual para cada imagem baseada em suas propriedades, e pode ser calculada por meio da Equação 11 (KORZYNSKA et al., 2013):

$$T(x, y) = M(x, y) \quad (11)$$

Onde $T(x, y)$ representa o valor do limiar da imagem e $M(x, y)$ representa a média de todos os pixels dentro de (x, y) , ou seja, todos os pixels que se encontram na imagem.

A aplicação da segmentação não objetiva realizar o reconhecimento de elementos individuais da imagem e suas relações. O processo visa apenas dividir uma imagem em regiões de *pixels* relevantes para assim facilitar sua análise. Ou seja, separar elementos significativos das regiões de interesse, variando de acordo com a aplicação (MARCOMINI, 2013).

4.2 EQUALIZAÇÃO DE HISTOGRAMA

O histograma de uma imagem indica a probabilidade de distribuição de níveis de cinza da mesma. Muitas imagens têm seus histogramas desviados, tanto para os níveis de cinza mais claros, quanto para os mais escuros, o que acarreta em perda de informação visual. A partir disso, se viu a necessidade de manipular imagens de forma a modificar a sua distribuição de níveis de cinza (LIMA, 2009).

A equalização de histograma surge como uma ferramenta que realiza a uniformização de histogramas. Essa ferramenta redistribui os níveis de cinza de forma uniforme, assim melhorando a qualidade visual da imagem (LIMA, 2009).

Tal técnica permite melhorar a discriminação entre elementos pertencentes a imagem e pode ser calculada utilizando a Equação 12 (PATEL et al., 2014):

$$S_k = (2^B - 1) \sum_{j=0}^k P_r(r_j) \quad (12)$$

Sendo B o número de *bits* da imagem, r_j o nível de cinza dos pixels da imagem, P_r a probabilidade do nível de cinza r_j ocorrer na imagem. A variável S_k representa uma função de distribuição acumulada, no processamento cada *pixel* de valor r_k é substituído pelo valor de S_k para que se obtenha a redistribuição de intensidade de cores desejada.

4.3 OPERADORES MORFOLÓGICOS

As operações morfológicas consistem em técnicas de extração de características de imagens. Tais operações são utilizadas para a identificação de padrões, e também auxiliam na atenuação de ruídos que prejudicam a representação dos objetos nas imagens. Sendo assim, o uso destas operações evidencia as regiões de interesse e destaca suas principais características (ELPÍDIO, 2012).

Existem diversas operações morfológicas e a mais adequada a se utilizar depende do objetivo da aplicação. Segue uma breve descrição das principais operações:

Dilatação – combina dois conjuntos através da adição vetorial de elementos dos conjuntos. O elemento estruturante é aplicado de forma concêntrica sobre um conjunto de pontos predefinido de uma imagem, de tal forma que o elemento estruturante adicione informação sobre a vizinhança desses pontos. Essa operação tem como principal objetivo o preenchimento de intervalos e lacunas indesejáveis na imagem.

Erosão – realiza o inverso da dilatação, combina dois conjuntos e realiza a subtração vetorial entre os conjuntos por onde o elemento estruturante percorre. Esta operação tem como principal finalidade a extração de detalhes e ruídos indesejáveis na imagem.

Abertura – consiste na aplicação de uma dilatação seguida de uma erosão. Com aplicação da erosão pretende-se eliminar ruídos e abrir lacunas em regiões de fraca conexão entre objetos. O resultado da operação anterior passa por uma dilatação que visa restaurar as dimensões reais dos objetos na imagem.

Fechamento – é a operação inversa a abertura (erosão seguida de uma dilatação) e tem como intuito a restauração de conexões fracas entre objetos da imagem (ELPÍDIO, 2012, p. 44).

5 METODOLOGIA

Como já citado, esse trabalho objetiva desenvolver uma RNA do tipo MLP para localização e classificação de microcalcificações mamárias em imagens mamográficas com o intuito de operar como um SAD. A metodologia utilizada para o desenvolvimento desse estudo pode ser observada na Figura 6 e cada etapa é melhor explicada nos próximos itens.



Figura 6. Etapas de desenvolvimento do SAD.

5.1 COLETA DE DADOS

A primeira etapa consiste na coleta de dados de imagens mamográficas com calcificações suspeitas de malignidade. Essas imagens foram fornecidas pela Clínica Janice Lamas Radiologia (CLJR). Para esse estudo foram selecionadas mamografias que possuem calcificações que se encaixam na categoria 4 do BI-RADS, as imagens que não possuíam achados passíveis de investigação foram eliminadas. Essa seleção foi realizada com a ajuda de um profissional da área, a qual indicou a categoria 4. Esta foi escolhida por conta de sua importância clínica e da complexidade de diagnóstico diferencial.

O grupo de amostragem desse estudo foi constituído por 37 imagens mamográficas. Esse grupo selecionado foi levado para a análise por um especialista, o qual realizou a extração manual de 106 Regiões de Interesse (ROIs), todas com o tamanho de 200 x 200 *pixels*. As imagens foram classificadas em dois grupos: Falso Positivo (FP) – composto por 55 imagens - e Verdadeiro Positivo (VP) – composto por 51 imagens. As classificações foram realizadas por meio de biópsia.

Porém, algumas das imagens fornecidas possuíam uma qualidade muito inferior as outras. Fatores como ruído muito intenso ou imagens com pouca variação nos níveis de cinza prejudicam a execução do PDI, acarretando em resultados não satisfatórios. Por esse motivo, alguns exames foram desconsiderados, pois, já que não possuíam a qualidade adequada, poderiam prejudicar no aprendizado do sistema. Sendo assim, o valor final de imagens utilizadas neste estudo foi de 70 imagens, sendo 35 classificadas como VP e 35 como FP.

Para assegurar a *performance* do sistema e para que não ocorra *overfitting*, o conjunto de imagens foi ampliado artificialmente por meio de técnicas de PDI, as quais serão melhor detalhadas no capítulo de resultados. Após esse processo, o número

final de imagens utilizadas pelo sistema foi de 140 imagens, sendo 70 classificadas como VP e 70 como FP.

5.2 PROCESSAMENTO DE IMAGENS

Com o objetivo de reduzir a quantidade de informações contidas nas imagens e assim facilitar e aumentar a eficiência de aprendizado do sistema, foram realizados alguns testes utilizando diferentes técnicas de PDI, todas elas foram implementadas utilizando a biblioteca *OpenCV*.

No primeiro deles foi utilizada nas imagens a técnica de segmentação com limiar adaptativo na qual foi realizada uma segmentação individual para cada imagem baseada em suas propriedades, podendo ser calculada por meio da Equação 11.

O segundo teste foi realizado utilizando duas técnicas: equalização de histograma seguido por segmentação com limiar adaptativo. A manipulação do contraste foi realizada utilizando equalização de histograma, a qual uniformiza a distribuição dos níveis de cinza da imagem e é calculada pela Equação 12. Após a manipulação do contrataste, a imagem foi submetida a segmentação com limiar adaptativo, que pode ser calculada por meio da Equação 11.

O terceiro teste também foi realizado utilizando duas técnicas: segmentação com limiar adaptativo seguido por fechamento. O fechamento consiste da operação morfológica que aplica uma erosão seguida de uma dilatação. Esse processo realiza a extração de ruídos e o preenchimento de lacunas indesejáveis na imagem.

O uso de mais de uma técnica de PDI foi realizado para avaliar com qual técnica o sistema apresentaria um melhor desempenho, apresentando melhores valores de acurácia.

5.3 SISTEMA COMPUTACIONAL

A próxima etapa do desenvolvimento do trabalho consiste na elaboração de uma RNA do tipo MLP para a identificação de microcalcificações nas imagens mamográficas selecionadas. O tipo da RNA foi escolhido levando em consideração que se trata de um problema de reconhecimento de padrões complexa, sendo MLP o tipo mais adequado para essa aplicação.

A RNA foi treinada utilizando o paradigma de aprendizagem supervisionado, por meio do algoritmo *Backpropagation*, que se baseia no ajuste de parâmetros da rede, de acordo com o erro da resposta do sistema.

Assim que a RNA é desenvolvida, é iniciada a fase *forward*, utilizada para definir a saída do sistema para uma determinada entrada. A saída real da RNA é comparada à saída desejada e um sinal de erro é calculado para cada nó de saída. Logo após, a fase *backward* utiliza o erro calculado para atualizar os pesos de suas conexões para fazer com que a resposta real se aproxime da resposta desejada. Este processo segue até que o erro atinja um valor de erro pré-determinado.

Além do erro quadrático médio estipulado, a RNA também pode utilizar o parâmetro de quantidade máxima de épocas como critério de parada. Outros parâmetros também alteram o desempenho da RNA, como: taxa de aprendizagem, *momentum*, pesos das conexões, número de neurônios em cada camada, função de ativação, entre outros.

Para definir os valores dos parâmetros para os quais a RNA opere da forma mais eficiente possível, foi utilizada a função *Grid Search* da biblioteca *Scikit-Learn*. Tal função realiza a busca, a partir de um intervalo de valores fornecidos para cada parâmetro, realizando a combinação de todos os valores fornecidos.

Após fornecidos os valores e compilada todas as combinações possíveis é retornada a RNA que obteve o melhor resultado e também os valores de todos os parâmetros que compuseram aquela RNA. Assim, por meio da função *Grid Search* foi possível obter os parâmetros que geraram a RNA com melhor acurácia.

A RNA foi elaborada utilizando a linguagem *Python*. A escolha desta linguagem foi feita devido a mesma dispor de uma grande quantidade de bibliotecas elaboradas, o que facilitou o desenvolvimento do sistema.

5.4 TREINAMENTO, VALIDAÇÃO E TESTE

A última etapa do estudo consiste no treinamento, validação e teste da RNA afim de avaliar seus resultados e sua capacidade de generalização para trabalhar como um SAD.

O treinamento foi realizado com o conjunto de imagens de treinamento, sendo concluído por um dos critérios de parada referidos: erro médio quadrático mínimo ou número máximo de épocas. Quando finalizado, foi possível ter acesso aos valores de

parâmetros e pesos que ofereceram os melhores resultados para o sistema. A validação foi realizada ainda durante o treinamento para avaliar periodicamente o aprendizado do sistema. Já a fase de teste ocorreu ao final da etapa de treinamento. Nela foi possível observar a capacidade de generalização da RNA, utilizando imagens do conjunto de testes, as quais não foram utilizadas no treinamento nem na validação, sendo completamente desconhecidas pelo sistema.

As três etapas foram realizadas para os bancos de imagens submetidos as três técnicas de PDI citadas afim de estabelecer qual delas oferece o melhor resultado.

6 RESULTADOS E DISCUSSÕES

Os resultados dispostos nessa seção são aqueles obtidos por meio de técnicas de PDI aplicadas a imagens que serviram de entrada a uma RNA, as quais tem o objetivo de localizar e classificar microcalcificações em exames de mamografia. Por se tratar de uma tarefa de grande complexidade, esse estudo teve como proposta atuar como um SAD para servir de segunda opinião para os especialistas.

6.1 RESULTADOS INICIAIS

Como apresentação de resultado inicial deste trabalho foi desenvolvida uma RNA para a solução do problema da porta lógica ou-exclusivo (XOR). Trata-se de um problema de baixa complexidade, também chamado de *Toy Problem*. A arquitetura neural utilizada foi composta por três camadas, uma de entrada, uma oculta e uma de saída, tendo dois neurônios na camada oculta e um na camada de saída, originariamente.

A RNA foi desenvolvida no ambiente *Python* e o algoritmo utilizado foi o *Backpropagation*. Para obter os melhores parâmetros para a solução do problema, todas as variáveis foram testadas, uma por vez, para que fosse definido o melhor valor de cada uma delas para esta aplicação. Os testes das variáveis para a função de ativação Sigmoidal podem ser observados na Tabela 1. No teste um parâmetro varia, enquanto os outros permanecem constantes, e como resultado da variação desse parâmetro é obtido o valor do erro da saída quando a RNA converge.

Tabela 1. Teste de parâmetros da RNA para a função de ativação Sigmoidal.

Taxa de Aprendizado	<i>Momentum</i>	Épocas	Bias	Erro
0,01	0,9	10000	Verdadeiro	$2,5 \times 10^{-29}$
0,7	0,9	10000	Verdadeiro	0,465
0,9	0,9	10000	Verdadeiro	0,555
0,01	0,1	10000	Verdadeiro	0,127
0,01	0,5	10000	Verdadeiro	$2,5 \times 10^{-14}$
0,01	0,9	10000	Falso	0,076

São considerados os melhores parâmetros aqueles para os quais a RNA obteve o menor erro possível. No caso da função de ativação Sigmoidal, os parâmetros que forneceram os melhores resultados, foram taxa de aprendizagem igual a 0.01, o termo momento igual a 0.9, Bias positivo e 10000 épocas, fornecendo o erro de $2,5 \times 10^{-29}$. Na Figura 7 é possível observar o treinamento do problema XOR para estes parâmetros.

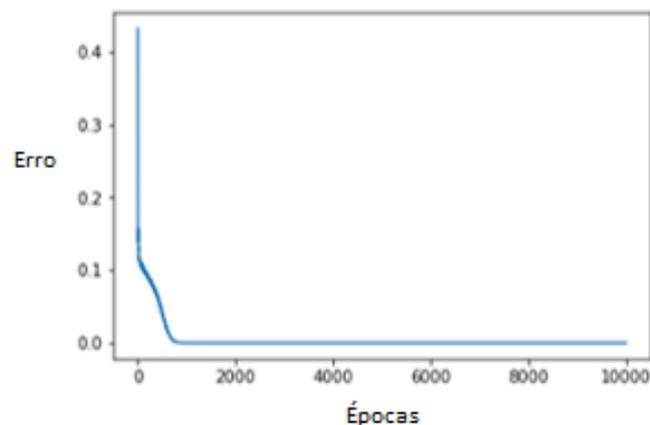


Figura 7. Treinamento do problema XOR para a função de ativação Sigmoidal.

O mesmo processo de teste foi repetido utilizando a função de ativação Tangente Hiperbólica. Os resultados podem ser observados na Tabela 2.

Tabela 2. Teste de parâmetros da RNA para a função de ativação Tangente Hiperbólica.

Taxa de Aprendizado	<i>Momentum</i>	Épocas	Bias	Erro
0,01	0,9	10000	Verdadeiro	$7,1 \times 10^{-31}$
0,7	0,9	10000	Verdadeiro	2,699
0,9	0,9	10000	Verdadeiro	3,520
0,01	0,1	10000	Verdadeiro	0,033
0,01	0,5	10000	Verdadeiro	$4,5 \times 10^{-30}$
0,01	0,9	10000	Falso	$3,72 \times 10^{-30}$

No caso da função de ativação Tangente Hiperbólica, os parâmetros que forneceram os melhores resultados, foram taxa de aprendizagem igual a 0.01, o termo momento igual a 0.9, Bias positivo e 10000 épocas, fornecendo o erro de $7,1 \times 10^{-31}$. Na Figura 8 é possível observar o treinamento do problema XOR para estes parâmetros.

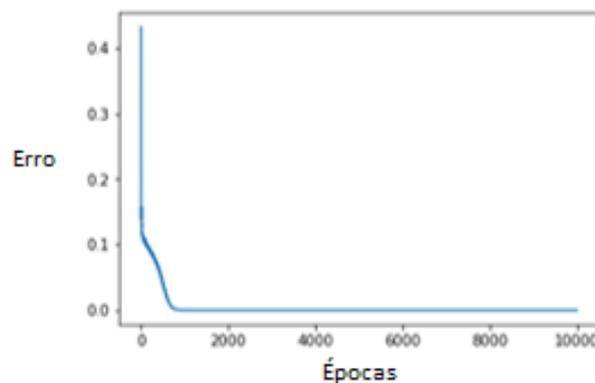


Figura 8. Treinamento do problema XOR para a função de ativação Tangente Hiperbólica.

Com base nos resultados obtidos, pode-se observar que o erro obtido para a função de ativação Tangente Hiperbólica foi menor. Sendo assim, os valores iniciais para este parâmetro e os das demais variáveis matemáticas utilizados para o desenvolvimento da RNA foram aplicados para o caso real em estudo.

6.2 BANCO DE DADOS

Para garantir a *performance* do sistema e para que não ocorresse *overfitting*, o conjunto de imagens foi ampliado artificialmente, por meio de PDI, de 70 para 140 imagens. Esse aumento foi possível com a rotação das imagens, na qual foram rotacionadas em 90° . Tal técnica de PDI foi realizada utilizando a biblioteca *Python Image Library* (PIL). Uma ilustração das alterações das imagens pode ser observada na Figura 9.

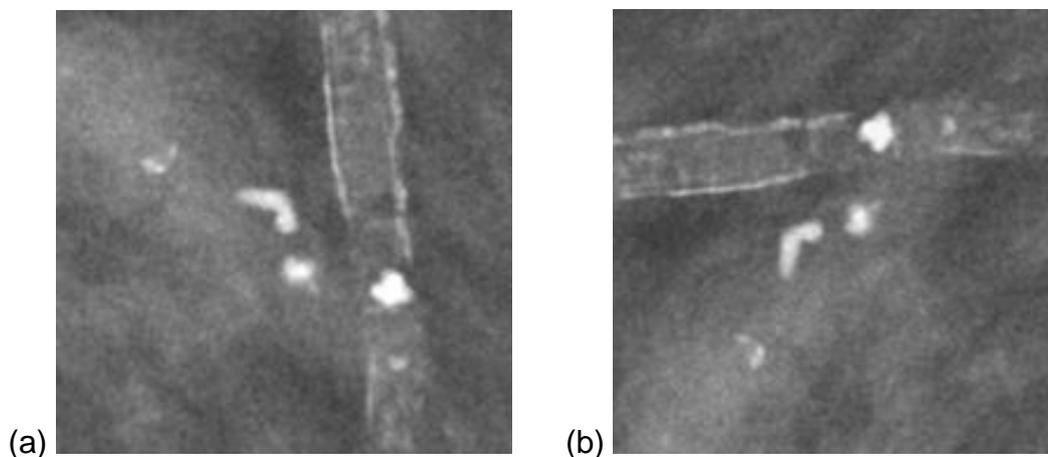


Figura 9. Resultado do processo de rotação: (a) Imagem Original, (b) Imagem Rotacionada.

Nessa etapa o PDI não realiza extração de características das imagens, apenas rotaciona a imagem original. Assim, não altera as características das microcalcificações contidas nas imagens, apenas seu posicionamento.

6.3 PROCESSAMENTO DE IMAGENS

Após ter o grupo de imagens aumentado artificialmente, todas elas foram redimensionadas para o tamanho de 200×200 *pixels* para tornar mais fácil a manipulação dos dados pelo sistema.

Com as imagens redimensionadas foi dado início ao processo de PDI. Nessa etapa as imagens foram submetidas as diferentes técnicas de PDI citadas no item 6.2, todas elas foram aplicadas utilizando a biblioteca *OpenCV*. Tais técnicas foram selecionadas pois constam na literatura como as mais adequadas para esse tipo de

aplicação, as quais foram também utilizadas neste trabalho. A Figura 10 apresenta uma comparação entre as técnicas utilizadas e seus resultados.

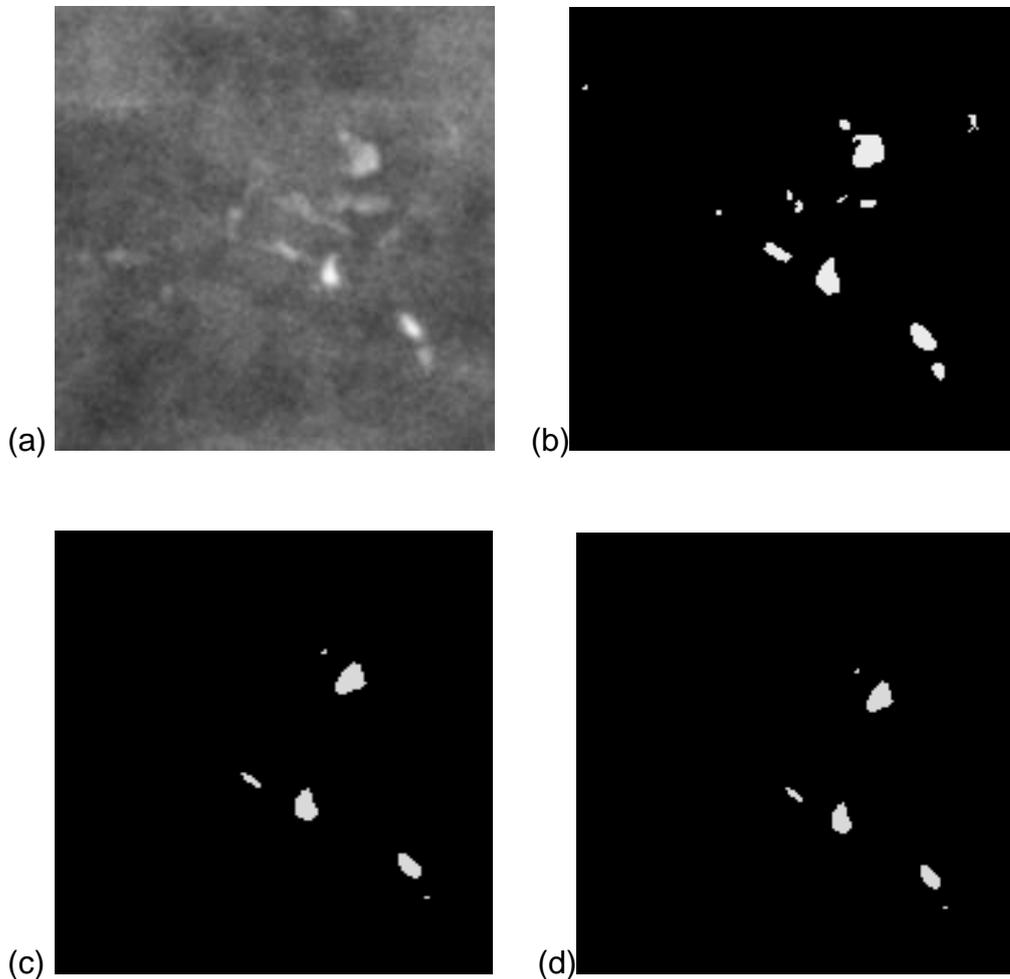


Figura 10. Resultado da etapa de PDI para cada técnica utilizada: (a) Imagem original; (b) Segmentação com limiar adaptativo; (c) Equalização de histograma seguido de segmentação com limiar adaptativo; (d) Segmentação com limiar adaptativo seguido de fechamento.

Todas as técnicas utilizadas realizam a binarização da imagem, favorecendo a distinção entre os objetos desejados e o fundo. Porém, os processos se dão de formas diferentes para cada técnica aplicada, como explicitado na seção 5.2.

Dentre os resultados obtidos é possível observar que a Figura 10 (b), por passar por apenas uma técnica de PDI, apresenta como resultado uma binarização detalhada, onde ocorre uma maior presença de ruídos. Já na Figura 10 (c) e (d), por passarem por mais de uma técnica de PDI, verifica-se uma binarização com redução de detalhes, ou seja, menor presença de ruídos. A Figura 10 (d) apresenta ainda

objetos com formas mais definidas do que as técnicas anteriores. Mais de uma técnica foi utilizada para que todas sirvam como entrada da RNA e se possa verificar com qual delas o sistema apresenta um melhor aprendizado e, conseqüentemente, uma melhor eficiência em seus resultados.

6.4 SISTEMA COMPUTACIONAL

A RNA desenvolvida para esse estudo foi treinada utilizando o algoritmo *Backpropagation* e foi elaborada utilizando a biblioteca *Scikit Learn*. A estrutura da RNA foi consistida em três camadas: A camada de entrada, a camada oculta e a camada de saída. A primeira camada foi composta por 40.000 neurônios, número correspondente a cada *pixel* das imagens que serviram como entrada do sistema – que tinham tamanho 200x200 *pixels*. A camada de saída, que representa o resultado do sistema, foi composta por dois neurônios na camada de saída: um classifica a imagem como FP e o outro como VP. Já a camada intermediária teve seu valor calculado utilizando a Equação 5, que forneceu o resultado de 202 neurônios.

A definição dos outros parâmetros da RNA, como taxa de aprendizado, *momentum* e função de ativação, foi estabelecida utilizando a ferramenta *Grid Search*. Para cada parâmetro foi definido manualmente um intervalo de valores possíveis que o mesmo poderia assumir. Para definição do número de neurônios na camada oculta, foram utilizados valores que se aproximavam daquele fornecido pela Equação 5 para estimar qual apresentaria o melhor resultado.

Os intervalos de valores fornecidos para a ferramenta nessa etapa foram os intervalos típicos de cada parâmetro encontrados na literatura, variando dos valores mínimos aos máximos que o parâmetro poderia assumir. Na Tabela 3 é possível observar os intervalos de alguns dos parâmetros fornecidos para a ferramenta *Grid Search* nessa etapa.

Tabela 3. Valores dos parâmetros fornecidos pela ferramenta *Grid Search*.

Parâmetro	Valores atribuídos
Função de ativação	Tangente Hiperbólica, Sigmóide, ReLU
Taxa de aprendizado inicial	0.001 a 0.999
Cronograma de taxa de aprendizado	Constante, Adaptativo
<i>Momentum</i>	0.001 a 0.999
Número de neurônios na camada oculta	150, 202, 250, 300

A ferramenta compilou todas as combinações de parâmetros, retornando aqueles que forneceram a RNA com o melhor resultado. Os valores para cada parâmetro fornecido pela ferramenta podem ser observados na Figura 11.

```
MLPClassifier(activation='tanh', alpha=0.999, batch_size='auto', beta_1=0.9,
              beta_2=0.999, early_stopping=False, epsilon=1e-08,
              hidden_layer_sizes=150, learning_rate='constant',
              learning_rate_init=0.7495, max_iter=2000, momentum=0.0003,
              nesterovs_momentum=True, power_t=0.5, random_state=None,
              shuffle=False, solver='adam', tol=1e-16, validation_fraction=0.1,
              verbose=False, warm_start=False)
```

Figura 11. Valores definidos para cada parâmetro pela ferramenta *Grid Search*.

Observando os valores obtidos pelo *Grid Search* pôde-se constatar que muitos dos parâmetros encontrados não são similares com aqueles utilizados no *Toy Problem*, apresentado na seção de Resultados Iniciais desse estudo. Isso ocorreu por se tratar de problemas muito distintos, sendo o *Toy Problem* um problema de baixa complexidade, não sendo esse o caso do SAD. Os ajustes dos parâmetros se dão de acordo com cada aplicação, demonstrando que os parâmetros ajustados para uma determinada aplicação não serão necessariamente ideais para uma diferente situação.

Como a ferramenta encontrou os valores para qual a RNA apresentou o melhor desempenho, os mesmos foram mantidos e utilizados para realizar as próximas etapas de validação e testes.

6.5 TREINAMENTO, VALIDAÇÃO E TESTE

Nesse estudo, após o aumento artificial por meio de técnicas de PDI, foram obtidas um total de 140 imagens de ROIs. Utilizando o método de *cross-validation* para avaliar a capacidade de generalização da RNA, o conjunto de amostras foi dividido da seguinte forma: 70% (98 imagens) foram utilizadas como conjunto de treinamento, 15% (21 imagens) como conjunto de validação e 15% (21 imagens) como grupo de teste. A quantidade de imagens selecionadas para compor cada conjunto, seguindo o método *cross-validation*, foi estabelecida de acordo com a literatura, como explicitado na seção 3.7.

O conjunto de amostras original foi submetido a três técnicas de PDI, resultando em três conjuntos de amostras diferentes, os quais serviram como entrada da RNA e passaram pelas etapas de treinamento, validação e teste para verificar com qual deles o sistema apresenta um melhor resultado.

Os parâmetros utilizados para o treinamento do sistema foram aqueles encontrados pela ferramenta *Grid Search* como sendo os valores ideais para a aplicação. A avaliação do desempenho da RNA iniciou-se no treinamento, quando o conjunto de validação foi utilizado durante o processo para realizar a otimização dos parâmetros. O valor da acurácia alcançada para cada um dos três conjuntos de validação utilizados nesse estudo, pode ser observado na Tabela 4.

Tabela 4. Acurácia alcançada pela RNA para os conjuntos de validação.

Técnica de PDI utilizada no conjunto de validação	Acurácia alcançada pela RNA
Segmentação com limiar adaptativo	72,73%
Equalização de histograma + Segmentação com limiar adaptativo	77,23%
Segmentação com limiar adaptativo + Fechamento	81,82%

Baseado na eficiência obtida com o conjunto de validação, foi realizada a avaliação da capacidade de generalização da RNA com os conjuntos de teste, ou seja, imagens desconhecidas pelo sistema, que não foram utilizadas durante o treinamento

e nem durante a validação. Os valores de acurácia atingidos para os conjuntos de teste podem ser observados na Tabela 5.

Tabela 5. Acurácia alcançada pela RNA para os conjuntos de teste.

Técnica de PDI utilizada no conjunto de teste	Acurácia alcançada pela RNA
Segmentação com limiar adaptativo	52,39%
Equalização de histograma + Segmentação com limiar adaptativo	57,14%
Segmentação com limiar adaptativo + Fechamento	61,90%

Como pode ser observado nas Tabelas 4 e 5, os valores de acurácia alcançados para o conjunto de validação foram maiores do que os alcançados para os conjuntos de teste. Isso acontece, pois, o conjunto de validação é composto por imagens já conhecidas pelo sistema. Sendo assim, a incidência de acerto é maior nesse grupo, enquanto o conjunto de teste são imagens totalmente desconhecidas pelo sistema. Por isso, com o conjunto de testes, é avaliada a capacidade de generalização do sistema.

Tanto no conjunto de validação quanto no de teste, a maior acurácia alcançada foi obtida nos grupos compostos pelas imagens que foram submetidas as técnicas de PDI de segmentação com limiar adaptativo seguido de fechamento. Dentre as técnicas utilizadas é possível observar que essa apresenta uma menor presença de ruídos e objetos com formas mais definidas do que as outras. Analisando os resultados obtidos, pôde-se concluir que essa é a técnica para a qual o sistema apresenta um melhor aprendizado.

7 CONCLUSÕES E TRABALHOS FUTUROS

A mamografia é um dos exames mais utilizados para a detecção precoce do câncer de mama. Entretanto, o diagnóstico por meio desse exame é uma tarefa de grande complexidade até mesmo para especialistas experientes, devido à dificuldade e a subjetividade na análise das imagens.

Esse estudo foi proposto com o objetivo de desenvolver um SAD utilizando técnicas de RNA, que possa servir como uma segunda opção para o especialista responsável por essa tarefa. Analisando os resultados obtidos no estudo, é possível concluir que as RNA desempenham eficientemente a tarefa de reconhecimento de padrões.

Os índices de acerto relativamente baixos obtidos no estudo são atribuídos a pequena quantidade de imagens disponíveis para o treinamento da RNA. Por se tratar de um problema de alta complexidade, seriam necessárias mais imagens para que o aprendizado ocorresse de forma mais eficiente e a RNA apresentasse uma melhor capacidade de generalização.

Apesar dos índices de acerto obtidos terem sido menores do que os esperados, pode-se afirmar que o sistema desenvolvido pode ter grande utilidade no campo da saúde, podendo ser utilizado para confirmar diagnósticos ou como auxílio para o treinamento de profissionais.

Como trabalhos futuros sugere-se o treinamento do sistema desenvolvido com mais imagens, para que se obtenha uma melhor capacidade de generalização e, conseqüentemente, um maior índice de acertos. Propõe-se também um sistema completamente integrado, onde haja a extração de ROIs e PDI automático, para que a imagem processada seja analisada pelo sistema. Por fim, propõe-se aplicar o SAD desenvolvido nesse estudo em clínicas e hospitais, para que possa ser utilizado na prática para auxiliar no diagnóstico do câncer de mama.

REFERÊNCIAS

- AFFONSO, E. T. F.; SILVA, A. M.; SILVA, M. P.; RODRIGUES, T. M. D.; MOITA, G. F. **USO REDES NEURAS MULTILAYER PERCEPTRON (MLP) EM SISTEMA DE BLOQUEIO DE WEBSITES BASEADO EM CONTEÚDO**. Centro Federal de Educação Tecnológica de Minas Gerais, Belo Horizonte, 2010.
- AGUILLAR, V. L.; BAUAB, S. P.; MARANHAO, N. M. **Mama - Diagnóstico por Imagem**. Rio de Janeiro, Brasil: Revinter, p. 22, 23, 2009.
- AMBRÓSIO, P. E. **Redes neurais artificiais no apoio ao diagnóstico diferencial de lesões intersticiais pulmonares**. Dissertação (Mestrado) – Faculdade de Filosofia Ciências e Letras de Ribeirão Preto, Universidade de São Paulo, 2002.
- BARCA, M. C. S.; SILVEIRA, T. R. S.; MAGINI, M. **TREINAMENTO DE REDES NEURAS ARTIFICIAIS: O ALGORITMO BACKPROPAGATION**. Encontro Latino Americano de Pós-Graduação – Universidade do Vale do Paraíba, 2005.
- BILMORIA M. M. **The woman at increased risk for breast cancer:evaluation and management strategies**. *Cancer*, p. 263-278, 1995.
- BITENCOURT, D. **Estratégias de Previsão de Geração de Energia Eólica Utilizando Redes Neurais Artificiais**. Dissertação de Mestrado. Universidade Federal de Sergipe. São Cristóvão - Sergipe. Fevereiro de 2015.
- BORGHESAN, D. H. P.; BARAÚNA, M.; PELLOSO, S. M.; CARVALHO, M. D. B.; **Auto-exame das mamas: conhecimento e prática entre profissionais da área da saúde de uma instituição pública**. *Acta Scientiarum Health Sciences*. Maringá, v.25, n.1, p. 103-113, 2003.
- BOYLE, P. **Curente situation of screening for câncer**. *Ann Oncol*; 13 Supl 4, 2002. p.189-98.
- BRAGA, A.; CARVALHO, A.; LUDERMIR, T. **Redes Neurais Artificiais, Teorias e Aplicações**. Livros Técnicos e Científicos Editora S.A. Rio de Janeiro. 2000
- CHAKRABARTI, J.; Evans A. J.; JAMES J.; ELLIS, I. O.; PINDER, S. E.; MACMILLAN, R. D. **Accuracy of mammography in predicting histological extent of carcinoma ductal in situ (DCIS)**. *Eur J Surg Oncol*, 2006.
- CHALA, L. F.; BARROS, N.; **Avaliação das mamas com métodos de imagem**. *Radiol Bras* 2007; p. 4-6.
- COEIRA, E. W. **Artificial intelligence in medicine: the challenges ahead**. *Journal of the American Medical Informatics Association*, v.3, n.6, p. 363-366, 1996.
- CONDUTAS INCA **Câncer de Mama**. *Revista Brasileira de Cancerologia*, 47(1): 9-19, 2001.
- COSTA, F. M. L. **Ações de detecção precoce do câncer de mama realizadas por profissionais da estratégia da saúde**. 2009. 50 f. Dissertação de Mestrado, Universidade Federal do Rio Grande do Norte, Natal, 2009.
- COSTA, R. C. **Modelos Preditivos de Velocidade de Vento para Sistemas Eólicos Baseados em Redes Neurais Artificiais**. Trabalho de Conclusão de Curso – Universidade Federal da Paraíba, João Pessoa, 2016.
- EBERHART, R. C., DOBBINS, R. W. **Neural Network PC Tools. A Practical Guide**. Academic Press, 1991.

- ELPÍDIO, F. G. G. (2012). **Sistema de auxílio na avaliação de calcificações mamárias por processamento digital de imagens e inteligência artificial**. Dissertação de Mestrado em Engenharia Biomédica, Programa de Pós-Graduação em Engenharia Biomédica, Faculdade Gama, Universidade de Brasília, 2012.
- GIGER, M. L. **Computer-aided diagnosis of breast lesions in medical images**. Computing in Science & Engineering, p. 39-45, 2000.
- GLOBOCAN **Global Cancer Statistics**. URL: <http://www.iarc.fr> Acesso em 14/05/2017
- GOMES, O. F. M. **Processamento e análise de imagens aplicados à caracterização automática de materiais**. Dissertação (Mestrado), Departamento de Ciência de Materiais e Metalurgia, Pontifícia Universidade Católica do Rio de Janeiro, Distrito Federal, 2001.
- GONDIM, E. M. S. **Importância da punção aspirativa por agulha fina no diagnóstico precoce do carcinoma mamário**. Dissertação de Pós-Graduação em Citologia Clínica, Programa *Latu Sensu* da FVB – Faculdade Boa Viagem, 2013.
- HAYKIN, S. **Neural Networks and Learning Machines**, Third Edition. [S.l.: s.n.], 2009. ISBN 9780131471399.
- INCA **Tipos de Câncer: Mama**. Instituto Nacional de Câncer. URL: <http://www2.inca.gov.br/wps/wcm/connect/tiposdecancer/site/home/mama>. Acesso em 21/04/2017.
- KORZYNSKA, A., ROSZKOWIAK, L., LOPEZ C., BOSCH, R., WITKOWSKI, L., LEJEUNE, M. **Validation of various adaptive threshold methods of segmentation applied to follicular lymphoma digital images stained with 3,3'-Diaminobenzidine&Haematoxylin**. US National Library of Medicine National Institute of Health, 2013.
- KOVÁCS, Z. L. **Redes neurais artificiais: fundamentos e aplicações**. Editora Livraria da Física, 4ª Edição, São Paulo, 2006.
- LEBORGNE, R. **Diagnosis of Tumors of the Breast Simple Roentgenography: Calcifications in Carcinoma**. *AJR*, 1951.
- LIMA, J. J. P. **Técnicas de diagnóstico com raios X: aspectos físicos e biofísicos**. Editora Imprensa da Universidade de Coimbra, 2ª Edição, 2009.
- LOUVEIRA, M. H.; SOUZA, L. R. F.; CASTRO, I. M.; ELIAS, S.; SZEJNFELD, J; KEMP, C. **Avaliação e classificação ultra-sonográfica dos nódulos mamários: revisão da literatura e aspectos atuais**. Revista Imagem, p. 123-128, 2003.
- MARCOMINI, K. D. **Aplicação de modelos de redes neurais artificiais na segmentação e classificação de nódulos em imagens de ultrassonografia de mama**. Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia Elétrica e Área de Concentração em Processamento de Sinais e Instrumentação – Escola de Engenharia de São Carlos da Universidade de São Paulo, 2013.
- MARTINS, J.P.M. **EIR - Sistema CAD Para Extração e Classificação de Áreas de Interesse em Mamografia**. Dissertação de Mestrado em Engenharia Biomédica, Publicação 44A/2016, Programa de Pós-Graduação em Engenharia Biomédica, Faculdade Gama, Universidade de Brasília, Brasília, DF, 2016.

- PATEL, S.; GOSWAMI, M.. **Comparative Analysis of Histogram Equalization Techniques**. Contemporary Computing and Informatics (IC3I), 2014 International Conference on: IEEE, 2014.
- PERELMUTER, G., CARRERA, E. V., VELLASCO, M., PACHECO, A. **Reconhecimento de Imagens Bidimensionais utilizando Redes Neurais Artificiais**. Anais do VIII SIBGRAPI, pp. 197-203, 1995.
- PRATT, W. K. **Digital Image Processing: PIKS Inside**. John Wiley and Sons, Estados Unidos, 4th edition, 2006.
- NOGUEIRA, V. F. **Modelagem Tridimensional da Mama Feminina Baseada em Elementos Finitos**. Monografia (Graduação) – Universidade de Brasília, Faculdade do Gama, Brasília, 2016.
- RASCHKA, S. **Python Machine Learning**. Packt Publishing, 1ª Edição, 2015.
- RESENDE, L. M. P.; MATIAS, M. A. R. F.; OLIVEIRA G. M. B.; SALLES, M. A.; MELO, F. H. C.; GOBBI, H. **Avaliação de microcalcificações mamárias de acordo com as classificações do Breast Imaging Reporting and Data System (BI-RADS™) e de Le Gal**. Universidade Federal de Minas Gerais, Belo Horizonte, 2017.
- RINGBORG, U. *et al.* **The Swedish Council on Technology Assessment in Health Care (SBU) systematic overview of radiotherapy for cancer including a prospective survey of radiotherapy practice in Sweden 2001**. Summary and conclusions. *Acta oncológica*, 42.5-6, 357-365, 2003.
- SILVA, A. M. M. et al. **Aplicação de técnicas de morfologia matemática para identificação de fases em imagens de raios-X característicos**. XVIII Encontro Nacional de Física da Matéria Condensada, Sociedade Brasileira de Física Caxambu, MG, 06 a 10 de Junho, 1995.
- SILVA, A. O. **Transformada de watershed para a segmentação de imagens médicas da região pélvica**. 2003. Dissertação de Mestrado, Faculdade de Tecnologia, Universidade de Brasília, Brasília, 2003.
- SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas**. São Paulo: ArtLiber, 2010.
- SOUZA, F. H. **Mamografia Digital Em Computação Com Mamografia Convencional No Rastreamento De Câncer De Mama No Brasil: Revisão Sistemática, Custo Da Doença E Analise De Custo Efetivo-Efetivo No Sistema Único De Saúde**. (Tese) Programa de Pós-Graduação em Epidemiologia, Universidade Federal do Rio Grande do Sul. Faculdade de Medicina, 2012.
- STAVROS, A. T.; **New advances in breast ultrasound: computer-aided detection**. *Ultrasound Clinics*, v. 4, n. 3, p.285-290, jul.2009.
- TAHMOUSH, D. (2007) **Image differencing approaches to medical image classification**. In: 36th IEEE Applied Imagery Pattern Recognition Workshop - AIPR, Washington, p.22 27.
- VERAS, C. **Estudo Comparativo de Técnicas de Redes Neurais Artificiais na Previsão da Velocidade do Vento em Curto Prazo**. Trabalho de Conclusão de Curso. Universidade de Pernambuco. Novembro de 2013.
- VIEIRA, A. V.; TOIGO, F. T. **CLASSIFICAÇÃO BI-RADS™: CATEGORIZAÇÃO DE**

4.968 MAMOGRAFIAS. Radiol Bras 2002;35(4):205–208.

APÊNDICES

APÊNDICE A – ALGORITMO DE DESENVOLVIMENTO DA RNA PARA RESOLUÇÃO DO PROBLEMA XOR

```

from pybrain.supervised.trainers import BackpropTrainer
from pybrain.tools.shortcuts import buildNetwork
from pybrain.structure import TanhLayer, SigmoidLayer, LinearLayer
from pybrain.datasets import SupervisedDataSet
import matplotlib.pyplot as plt
import numpy as np
%matplotlib inline

net = buildNetwork(2,3,1, bias=True, hiddenclass= SigmoidLayer)
net._setParameters(np.random.uniform(-2,1,net.params.shape))

d = SupervisedDataSet(2,1)
d.addSample ([0,0],[0])
d.addSample ([0,1],[1])
d.addSample ([1,0],[1])
d.addSample ([1,1],[0])

trainer = BackpropTrainer(net, d, learningrate= 0.01, momentum= 0.9)

epocas= 10000
tol= 1e-10
erro= 0
total_epocas= 0
v_erro=[]

while epocas>0:
    erro= trainer.train()
    epocas= epocas-1
    total_epocas= total_epocas + 1
    v_erro.append(erro)

    if erro < tol:
        break
print 'Erro final: ', erro
print 'Total de epocas: ', total_epocas
print '00, saida: ', net.activate([0,0])[0]
print '01 saida: ', net.activate([0,1])[0]
print '10, saida: ', net.activate([1,0])[0]
print '11, saida: ', net.activate([1,1])[0]

```