



Universidade Federal da Paraíba
Departamento de Informática
Programa de Pós-Graduação em Informática

UM MÉTODO AUTOMÁTICO DE DETECÇÃO DE MASSAS EM MAMOGRAFIAS POR MEIO DE REDES NEURAIS

José Rogério Bezerra Barbosa Filho

João Pessoa
2012

José Rogério Bezerra Barbosa Filho

**UM MÉTODO AUTOMÁTICO DE DETECÇÃO DE
MASSAS EM MAMOGRAFIAS POR MEIO DE REDES
NEURAIS**

Dissertação apresentada como
requisito parcial para a obtenção
de título de Mestre pelo Programa
de Pós-Graduação em Informática
da Universidade Federal da
Paraíba.

Orientador: Prof. Dr. Leonardo
Vidal Batista

João Pessoa

2012

Joé Rogério Bezerra Barbosa Filho

TÍTULO: Mestre

Dissertação apresentada como requisito parcial para a obtenção de título de Mestre pelo Programa de Pós-Graduação em Informática da Universidade Federal da Paraíba.

Aprovado em ____/____/____

BANCA EXAMINADORA

Leonardo Vidal Batista

Homero Schiabel

Natasha Correia Queiroz Lino

Aos meus pais, pelo apoio e amor dado
que possibilitaram todas as minhas
conquistas.

AGRADECIMENTOS

Aos meus pais.

Ao meu orientador, Leonardo, por partilhar comigo muito de sua sabedoria e amizade.

Ao professor Homero e ao grupo LAPIMO, por todo o conhecimento, amizade e trabalhos compartilhados.

Aos amigos que sempre estiveram ao meu lado, mesmo quando geograficamente impossível, dando-me apoio e vontade de seguir em frente.

Aos Barufaldi, Pachiega e todos os outros que me acolheram e foram minha segunda família em São Carlos.

"Para um ser humano, nada vem naturalmente. (...) Temos que aprender tudo o que fazemos".

Philip Pullman

RESUMO

O câncer de mama é a causa mais comum de morte por câncer na população feminina e um sério problema de saúde mundial. A mamografia permite uma detecção precoce do câncer, reduzindo a mortalidade da doença. Sua eficiência tornou-a procedimento padrão para diagnóstico do câncer de mama. Essas razões levaram ao desenvolvimento de sistemas computadorizados para o auxílio à detecção e ao diagnóstico - em inglês, *Computer-Aided Detection and Diagnosis* (CADDx) - que auxiliam os profissionais da saúde provendo uma segunda opinião ao diagnóstico. Um dos algoritmos estudados durante o desenvolvimento do trabalho, o algoritmo para detecção de massas criado por Ozekes *et al*, mostrou grande potencial atingindo 99% de sensibilidade quando aplicado nas imagens testadas. Entretanto, seus muitos parâmetros, e a calibração manual de cada um deles, tornam impossível a aplicação do algoritmo na construção de sistemas CADDx reais. Esse trabalho apresenta um método automático para detecção de massas em mamografias baseado no algoritmo de Ozekes *et al*. Redes neurais artificiais (RNA) Perceptron multicamadas são usadas como aproximadores universais para a calibração dos parâmetros necessários ao método. A computação dessas redes produz os valores que deverão ser usados como parâmetros para as etapas de binarização e aplicação dos *templates*. A seleção de atributos e topologias das redes neurais foi definida empiricamente. Resultados mostram, na melhor configuração do sistema, 82% de sensibilidade 7,51 falsos positivos por imagem e, após uma redução de falsos positivos, 74% de sensibilidade e 3,56 de falsos positivos por imagem. Trabalhos futuros incluem o estudo de mais atributos e descritores de imagens além da experimentação de outros algoritmos para pré-processamento.

Palavras-chave: mamografia, CADDx, redes neurais artificiais, detecção, massas.

ABSTRACT

Breast cancer is the most common cause of death by cancer in the female population and a serious world health problem. The mammographic exam allows an early detection which reduces the mortality rate of the disease. Its efficiency has made it the standard procedure for breast cancer diagnosis. These reasons have led to the development of Computer-Aided Detection and Diagnosis (CADDx) systems that assist the physician by working as a second opinion in the diagnostic. One of the algorithms studied during the development of this work, the mass detection algorithm created by Ozekes *et al*, has shown great potential reaching 99% of sensibility when applied in the test group images. However, its many parameters and the need to manual calibrate them make it impossible to use it in the constructions of practical CADDx systems. This work presents an automatic method for mass detection in mammography based on the algorithm of Ozekes *et al*. Multilayer Perceptron artificial neural networks (ANN) are used as functional approximators to automatically calibrate the necessary parameters of the proposed method. The computation of the neural networks produces the values used as parameters for thresholding and template application stages. Feature selection and network topologies were chosen by means of empirical tests. Results show in its best configuration point 82% of sensibility and 7,51 false positives per image. After a false positive reduction, 74% of sensibility and 3,56 false positives per image were achieved. Future works include the study of a wider set of image features and preprocessing algorithms.

Keywords: mammography, CADDx, artificial neural networks, detection, masses

SUMÁRIO

RESUMO.....	5
ABSTRACT	8
SUMÁRIO.....	9
1. INTRODUÇÃO	13
1.1 O Que São Sistemas CADDx.....	13
1.2 Motivação.....	15
1.3 Objetivos	16
1.4 Disposição do Trabalho.....	16
2. REVISÃO BIBLIOGRÁFICA	19
2.1 Surgimento e Cenário Atual dos Sistemas CADDx.....	19
2.2 Sistemas para Detecção de Massas	20
2.3 Avaliação e Comparação de Sistemas CADDx.....	21
2.4 Utilização de Redes Neurais Artificiais em Sistemas CADDx	23
2.5 Sumário	24
3. FUNDAMENTAÇÃO TEÓRICA	25
3.1 Método de Marques para Delimitação do Contorno da Mama	25
3.2 Método de Ozekes para Detecção de Massas.....	27
3.3 Redes Neurais Artificiais	32
3.3.1 Neurônio Artificial.....	33

3.3.2	Redes Perceptron Multicamadas	35
3.3.3	Algoritmo Backpropagation e o Treinamento da Rede PML	37
3.3.4	Usando Redes Neurais PML como Aproximadores Funcionais	38
3.4	Descritores de Textura de Haralick	39
3.5	Momentos Invariantes de Hu	41
3.6	Binarização de Otsu	43
3.7	Crescimento de Região	43
3.8	Aumento de Contraste Logarítmico	44
3.9	Sumário	45
4.	MATERIAIS E MÉTODOS	47
4.1	Materiais	48
4.1.1	Software de Processamento de Imagens ImageJ	48
4.1.2	Framework de Redes Neurais Encog	49
4.1.3	Banco de Imagens DDSM	49
4.2	Arquitetura do Sistema CADDx Proposto	50
4.2.1	Pré-Processamento: Remoção das Bordas da Imagem	53
4.2.2	Segmentação	55
4.2.3	Recorte e Redimensionamento da Mama	58
4.2.4	Pré-Processamento: Aumento de Contraste e Redução de Ruído	58
4.2.5	Extração de Atributos da Imagem	60
4.2.6	Cálculo do Limiar da Binarização	60
4.2.7	Binarização da Imagem	60
4.2.8	Extração de Atributos da Imagem Binarizada	61

4.2.9 Cálculo do Raio do Template.....	61
4.2.10 Aplicação do Template	61
4.3 Configuração das Redes Neurais.....	63
4.4 Treinamento das Redes Neurais.....	64
4.5 Seleção de Atributos e Topologia da Rede	65
4.6 Avaliação da Detecção e Geração das Curvas FROC	68
4.7 Sumário	69
5. RESULTADOS.....	71
5.1 Remoção de Manchas Brancas nas Mamografias	71
5.2 Segmentação da Mama	72
5.3 Segmentação do Músculo Peitoral.....	73
5.4 Seleção de Atributos	75
5.5 Escolha das Topologias	80
5.6 Curvas FROC.....	85
5.7 Protótipo	88
6. DISCUSSÕES	91
6.1 Segmentação da Mama e do Músculo Peitoral	91
6.2 Seleção de Atributos	91
6.3 Escolha das Topologias	93
6.3 Desempenho Dos Métodos de Aplicação dos Templates	94
6.4 Desempenho do Sistema	95
6.5 Comparação Com Outros Trabalhos.....	96

7. CONSIDERAÇÕES FINAIS	101
REFERÊNCIAS BIBLIOGRÁFICAS	103
APÊNDICE A – EXPANSÃO DE HISTOGRAMA	109
A.1 Escolha da Distância no Cálculo dos Descritores de Haralick	109
A.2 Escolha dos Atributos.....	116
A.3 Escolha das Topologias	117
A.4 Curvas FROC.....	122
APÊNDICE B – EQUALIZAÇÃO DE HISTOGRAMA.....	125
B.1 Escolha da Distância no Cálculo dos Descritores de Haralick	125
B.2 Escolha dos Atributos.....	132
B.3 Escolha das Topologias	133
B.4 Curvas FROC.....	139
APÊNDICE C – AUMENTO DE CONTRASTE LOGARÍTMICO	143
C.1 Escolha da Distância no Cálculo dos Descritores de Haralick	143
C.2 Escolha dos Atributos	150
C.3 Escolha das Topologias	151
C.4 Curvas FROC.....	157

1. INTRODUÇÃO

O câncer de mama é o tipo de mais comum de câncer, desconsiderando os tumores de pele não melanoma, que atinge a população feminina (INCA e Ministério da Saúde, 2011), tornando-o um sério problema de saúde. Estimativas indicam que 410.000 mortes foram causadas por essa doença no ano de 2002 no mundo (BOYLE e LEVIN, 2008). Somente no Brasil, segundo o Instituto Nacional de Câncer, aproximadamente 52.680 novos casos de câncer de mama foram estimados para o ano de 2012 (INCA e Ministério da Saúde, 2011). Felizmente, sabe-se que o diagnóstico precoce da doença diminui consideravelmente sua taxa de mortalidade (BLANKS *et al*, 2000).

A mamografia, exame radiográfico da mama, permite a detecção do câncer de mama mesmo em seus estágios iniciais. Ao identificar as diferenças de densidades nos tecidos da mama, esse exame permite identificar lesões mesmo quando essas não são palpáveis, ou são estruturas mamárias modificadas (DOI *et al*, 2005). Por esses motivos, o Ministério da Saúde, em conjunto com o Instituto Nacional de Câncer, recomenda o rastreamento do câncer de mama por meio de mamografias anuais em mulheres acima dos 40 anos de idade (INCA e Ministério da Saúde, 2004). Devido a popularidade e a grande demanda desse exame, o estudo e desenvolvimento de sistemas para o auxílio à detecção e ao diagnóstico - em inglês, *Computer-Aided Detection and Diagnosis* (CADDx) - para mamografia tornaram-se comuns na literatura.

1.1 O Que São Sistemas CADDx

É possível encontrar uma distinção de nomenclatura entre sistemas especificamente focados na detecção de artefatos, muitas vezes chamados especificamente de CAdE ou apenas CAD, e sistemas focados na classificação – diagnóstico – desses achados, os chamados CADx (MASALA, 2006). Utiliza-se aqui uma definição mais ampla: é considerado um sistema CADDx qualquer sistema computacional que provê um auxílio ao profissional da saúde, seja esse auxílio dado na detecção, no diagnóstico ou em ambos os casos. Na prática, esses sistemas

funcionam como uma segunda opinião levada em consideração pelo radiologista na hora de dar o seu diagnóstico.

Em geral, um sistema CADDx para mamografia pode ser organizado nas seguintes etapas: aquisição da imagem, pré-processamento, segmentação, detecção, extração de atributos e classificação (MASALA, 2006). A etapa de pré-processamento tem como objetivo principal a redução do ruído da imagem e o melhoramento de seu contraste. A etapa de segmentação é responsável pela separação entre fundo e objeto da imagem. A etapa de detecção vai apontar para regiões contendo artefatos suspeitos como nódulos e calcificações. Nas etapas seguintes é feita a extração de atributos desses achados e, por fim, a classificação - diagnóstico - dessas regiões.



Figura 1 – Esquema geral das etapas de um CADDx

Apesar de contemplarem diversas áreas da radiologia, os sistemas CADDx para mamografia já estão consolidados na atual conjuntura existindo, inclusive, sistemas comerciais disponíveis para compra e uso clínico. Estudos comprovam que

a utilização de sistemas CADDx como uma segunda consulta pelo radiologista aumenta a taxa de detecção do câncer de mama significativamente (DOI, 2007).

1.2 Motivação

Diversos algoritmos para processamento de imagens digitais requerem o uso de parâmetros para o seu correto funcionamento. Muitas vezes, o ajuste manual desses parâmetros, mesmo quando feito por profissionais da área tecnológica, pode se tornar uma tarefa demorada e cansativa. Esse ajuste torna-se impraticável, se passa a ser feito por profissionais da saúde que geralmente não dispõem da técnica ou do tempo necessário para tal atividade.

Conclui-se, então, que um sistema CADDx deve possuir todo ou a maior parte de seu funcionamento automatizado evitando ao máximo a necessidade da intervenção do profissional da saúde que o opera para que seja aplicável a situações clínicas reais. Mesmo que um algoritmo mostre excelência na detecção de achados em imagens mamográficas, sua utilidade em um sistema comercial é reduzida se a calibração de diversos parâmetros é necessária toda vez que o sistema for executado.

O método de Ozekes *et al* para detecção de massas (OZEKES e OSMAN e ÇARMURCU, 2005) foi um dos algoritmos estudados durante a fase de revisão bibliográfica. A aplicação do algoritmo de forma manual, isto é, definindo manualmente os valores de seus parâmetros para cada imagem de teste escolhida nesse trabalho, mostrou que era possível detectar as massas cancerígenas em 99% dos casos. Percebeu-se que o algoritmo poderia ser usado na construção de um sistema CAD, específico para detecção, se a necessidade de calibrar seus parâmetros manualmente fosse eliminada.

As redes neurais artificiais, em específico as redes Perceptron multicamadas, possuem diversas aplicações. Uma delas é a capacidade de servir como aproximadores funcionais. Assumindo determinadas configurações necessárias a esse tipo de finalidade, uma rede Perceptron tem a capacidade de mapear qualquer função contínua no espaço das funções reais com apenas uma camada escondida de neurônios (SILVA e SPATTI e FLAUZINO, 2010). Supondo uma função contínua e real que, dado alguns atributos da imagem como entrada, forneça os valores corretos a ser usados como parâmetros no algoritmo proposto, uma rede neural

artificial Perceptron multicamada poderia ser usada como um aproximador funcional para essa função.

1.3 Objetivos

Esse trabalho tem como objetivo geral a pesquisa e o desenvolvimento de um sistema de detecção de massas (CAD) automático, baseando-se no método de Ozekes e utilizando redes neurais artificiais Perceptron multicamadas para obtenção automática dos parâmetros utilizados no algoritmo.

Os objetivos específicos são:

- Pré-processamento das imagens mamográficas com o intuito de aumentar o contraste e reduzir o ruído.
- Segmentação das imagens e identificação da região da mama, músculo médio-lateral e fundo da imagem.
- Implementação do algoritmo de Ozekes.
- Modificação do algoritmo de Ozekes para diminuir a quantidade de parâmetros necessários à sua execução.
- Utilização de redes multicamadas Perceptron como aproximadores universais para calibrar automaticamente os parâmetros do algoritmo proposto.

1.4 Disposição do Trabalho

Além deste capítulo introdutório, o trabalho é dividido em mais seis capítulos:

Capítulo 2: Revisão Bibliográfica – Apresenta um breve histórico sobre sistemas CADDx, trabalhos já existentes na literatura sobre detecção de massas e o uso das redes neurais artificiais nesses sistemas.

Capítulo 3: Fundamentação Teórica – Apresenta os conceitos e técnicas utilizadas no trabalho tais como: método de Marques para delimitação do contorno da mama (MARQUES, 2001), método de Ozekes para detecção de massas (OZEKES e OSMAN e ÇARMURCU, 2005), redes neurais artificiais, descritores de textura de Haralick (HARALICK e SHANMUGAM e DINSTEIN, 1973) e momentos invariantes de Hu (HU, 1962).

Capítulo 4: Materiais e Métodos – Descrição das bibliotecas, APIs, bancos de imagens, algoritmos e métodos utilizados na construção do sistema CAD proposto.

Capítulo 5: Resultados – Apresentação dos resultados obtidos na etapa de segmentação, seleção dos atributos, escolha das topologias das redes neurais e curvas FROC.

Capítulo 6: Discussões – Comentários e discussões referentes aos resultados obtidos.

Capítulo 7: Considerações Finais – Conclusões finais sobre o trabalho.

2. REVISÃO BIBLIOGRÁFICA

O estudo de sistemas voltados para o processamento de imagens médicas iniciou-se há aproximadamente 50 anos e, mais especificamente, o estudo de sistemas CADDx, há 20 anos. Hoje, é sabido que esses sistemas, quando usados como uma segunda opinião, melhoram o diagnóstico feito por radiologistas. Por essa razão, e por ser um tema de pesquisa consolidado e sabidamente apresentar resultados frutíferos, diversos trabalhos envolvendo sistemas CADDx estão presentes na literatura científica. Este capítulo apresenta uma introdução sobre o início do desenvolvimento dos sistemas CADDx até os dias atuais bem como trabalhos presentes na literatura sobre sistemas CADDx específicos para a detecção de massas.

2.1 Surgimento e Cenário Atual dos Sistemas CADDx

De acordo com as pesquisas realizadas por Doi (DOI, 2007), trabalhos envolvendo processamento de imagens médicas já existiam desde a década de 60, mas somente no início dos anos 80 o desenvolvimento e estudo de sistemas CADDx tornou-se significativo e sistemático na pesquisa científica. Esses estudos atingiram uma fase prática, isto é, cujos resultados podem ser aplicados em situações clínicas reais, primeiramente para a detecção de câncer de mama, pulmão e cólon. Grande parte desses exames apresenta resultados normais tornando a detecção de lesões um trabalho difícil e custoso para radiologistas e por isso, ainda segundo a pesquisa de Doi (DOI, 2007), os sistemas CADDx obtiveram seus primeiros resultados práticos nessas áreas.

A comercialização do primeiro sistema CAD foi um importante marco na evolução dos sistemas CADDx. A empresa *R2 Technology™*, baseando-se em licenças de tecnologias da Universidade de Chicago, conseguiu a aprovação da *United States Food and Drug Administration* (FDA) e lançou no ano de 1998 o *ImageChecker®*: primeiro sistema comercial para detecção de lesões em imagens mamográficas. A partir daí, outros sistemas CADDx foram criados, aprovados e comercializados, não somente nos Estados Unidos, e um número ainda maior passou a ser avaliado em diversos centros clínicos (DOI, 2005).

Com o lançamento de sistemas CADDx comerciais, surgiram também diversos estudos sobre a eficiência desses sistemas no uso clínico. Atualmente, é sabido que a utilização de sistemas CADDx por radiologistas como uma segunda opinião melhora significativamente os resultados de seu diagnóstico:

- Melhora de 20% na detecção precoce do câncer de mama (DOI, 2005).
- Aumento de 164% na detecção de pequenos tumores invasivos - menores que 1 cm (DOI, 2007);
- Redução de 5.3 anos na média da idade dos pacientes no momento em que a doença foi detectada (DOI, 2007);
- Mesmo quando operado como única fonte de consulta, obtenção de 80 a 100% de sensibilidade na detecção de agrupamentos de microcalcificações (BOYER *et al*, 2009);
- Sensibilidade de 88 a 92% na detecção de massas quando operando como única fonte de consulta (BOYER *et al*, 2009).

Nenhum sistema CADDx brasileiro foi aprovado para uso comercial até o momento, embora diversos grupos espalhados pelo país contribuam para a pesquisa científica nessa área. Um dos grupos mais consolidados e comprometidos com o desenvolvimento de um sistema CADDx completo é o Laboratório de Análise e Processamento de Imagens Médicas e Odontológicas (LAPIMO) do departamento de Engenharia Elétrica da Universidade de São Paulo (LAPIMO, 2011). O LAPIMO possui diversos artigos publicados sobre sistemas CADDx, alguns dos quais serviram de referências para este trabalho, além da pretensão de lançar um sistema clinicamente usável.

2.2 Sistemas para Detecção de Massas

A detecção de massas motivou a criação dos sistemas CADDx e é um foco abundante de pesquisa na área ainda nos dias atuais. Também chamados especificamente de CAdE ou apenas CAD, estima-se que a sensibilidade, isto é, a capacidade que esses sistemas possuem em detectar verdadeiros positivos, varia em média entre 88 a 92% (BOYER *et al*, 2009) e, embora seja possível encontrar taxas ainda mais altas de sensibilidade na literatura chegando até a 99% (BOSE e KARNAN e SIVAKUMAR, 2010; GAO, 2010), sistemas cuja sensibilidade se

aproxima da média citada tendem a ser considerados suficientes para prover um auxílio ao radiologista. Os sistemas específicos para detecção de massas tem a maior taxa de falsos positivos por imagem quando comparados a outros tipos de sistemas CADDx.

O *ImageChecker*[®], primeiro sistema CAD comercial aprovado nos Estados Unidos, é provavelmente um dos sistemas mais utilizados no país (HOLOGIC, 2011). Em sua versão 9.3, a configuração padrão do sistema resulta em 88% de sensibilidade podendo ser utilizada uma segunda configuração que aumenta essa taxa para 90%, embora haja um leve aumento na taxa de falsos positivos por imagem (IMAGECHECKER, 2011). Importante observar que as taxas obtidas pelo sistema não chegam a superar o estado da arte na detecção de massas citado anteriormente e, mesmo assim, é o sistema que possui liderança no mercado de CADDx comerciais americanos. A figura 2 mostra uma captura de tela do *ImageChecker*[®] ao detectar agrupamentos de microcalcificações.



Figura 2 – Imagem de uma tela do ImageChecker[®] mostrando a detecção de agrupamentos de microcalcificações por meio de marcações triangulares (HOLOGIC, 2011)

2.3 Avaliação e Comparação de Sistemas CADDx

A abordagem mais usada para comparar a eficiência de sistemas CADDx é a abordagem de estímulo e resposta da teoria de detecção de sinal. Nessa

abordagem, as imagens são tratadas como um estímulo positivo, caso apresentem alguma anormalidade, ou negativo, caso sejam imagens que não apresentem nenhuma patologia. O sistema, dado um estímulo como entrada, vai apresentar uma resposta positiva se detectou alguma anormalidade ou uma resposta negativo caso contrário (EVANS, 1981).

Assim, uma resposta positiva para um estímulo positivo é um verdadeiro positivo enquanto uma resposta positiva para um estímulo negativo é considerado um falso positivo. Analogamente, uma resposta negativa para um estímulo negativo é considerado um verdadeiro negativo e uma resposta negativa para um estímulo positivo é considerado um falso negativo. Com essas medidas, é possível medir a taxa de verdadeiros positivos de um sistema, também chamada de sensibilidade, e a taxa de falsos positivos, que é o complemento da medida de especificidade. As fórmulas (1) e (2) descrevem o cálculo das taxas citadas.

$$\text{taxa de verdadeiros positivos} = \text{sensibilidade} = \frac{\text{verdadeiros positivos}}{\text{verdadeiros positivos} + \text{falsos negativos}} \quad (1)$$

$$\text{taxa de falsos positivos} = 1 - \text{especificidade} = \frac{\text{falsos negativos}}{\text{falsos negativos} + \text{verdadeiros negativos}} \quad (2)$$

É natural que, ao mudar o rigor na classificação ou detecção de um sistema, as taxas de verdadeiros positivos e falsos positivos mudem. Um sistema menos rigoroso tende a ter uma taxa de verdadeiros positivos bastante alta em consequência de uma taxa de falsos positivos também elevada, talvez mais do que o tolerável. Já um sistema bastante rigoroso pode ter uma baixa taxa de verdadeiros positivos e ter a vantagem de ter pouquíssimos falsos positivos.

Uma curva ROC – do inglês, *Receiver Operating Characteristic* - é construída ao traçar o gráfico das taxas de verdadeiros positivos e falsos negativos de um sistema para diferentes configurações de sua execução em um gráfico de duas dimensões, alterando o rigor com que o sistema classifica os estímulos. A curva ROC mostra o comportamento geral do sistema CADDx permitindo analisar se o sistema possui as qualidades necessárias para o seu uso.

Nos sistemas especificamente voltados para detecção de estruturas, os sistemas CAD ou CAdE, utiliza-se as curvas FROC – do inglês, *Free-response Receiver Operating Characteristic* – que são semelhantes às curvas ROC diferindo

no uso da taxa de falsos positivos por imagem ao invés da taxa de falsos negativos. Analogamente a curva ROC, um comportamento normal esperado de uma curva FROC é que o número de falsos positivos por imagem do sistema aumente à medida que sua taxa de verdadeiros positivos, ou sensibilidade, também cresce. A figura 3 mostra as curvas FROC para detecção de microcalcificações e massas do sistema ImageChecker[®] versão 9.3.




Figura 3 – Curvas FROC para detecção de microcalcificações, gráfico da esquerda, e massas, gráfico da direita, do ImageChecker[®] versão 9.3 (HOLOGIC, 2011)

2.4 Utilização de Redes Neurais Artificiais em Sistemas CADDx

Uma rede neural artificial é um modelo computacional baseado no funcionamento do cérebro humano. Uma rede neural pode, dado um conjunto suficientemente grande de treinamento, generalizar regras com extrema eficiência (COPPIN, 2004). As redes neurais artificiais Perceptron multicamadas são aquelas que possuem uma ou mais camadas de neurônios escondidas, ou seja, camadas que estão localizadas entre a camada de entrada e a camada de saída. Essas redes podem ser usadas para diversas aplicações diferentes como o reconhecimento de padrões – classificação - e a aproximação funcional universal. A partir do final dos anos 80, essas redes vêm sendo utilizadas popularmente em diversas aplicações diferentes (SILVA e SPATTI e FLAUZINO, 2010).

A principal utilização das redes neurais artificiais Perceptron multicamadas na construção de sistemas CADDx é na forma de classificadores. Diversos trabalhos utilizam esse tipo de rede para classificar a malignidade de uma massa (BILSKA-

WOLAK *et al*, 2005; RIBEIRO, 2006; TANGARO *et al*, 2006). Mesmo em trabalhos voltados para a detecção de massas, redes neurais artificiais Perceptron multicamadas são utilizadas para classificar as regiões de interesse - em inglês, *regions of interest* (ROIs) - encontradas com o intuito de diminuir o número de falsos positivos de sistemas CAD (CASCIO *et al*, 2006; VAN ENGELAND, 2007).

2.5 Sumário

Apesar de estudos sobre processamento de imagens médicas datarem de 50 anos atrás, apenas na década de 80 o estudo de sistemas CADDx tornou-se significativo. Atualmente, sistemas CADDx para mamografias encontram-se em estágios mais avançados de maturidade existindo, inclusive, sistemas comerciais aprovados por órgãos públicos de saúde de seus países de origem. Quando utilizados como uma segunda opinião, esses sistemas comprovadamente aumentam as taxas de detecção e diagnóstico do câncer de mama.

Sistemas para detecção de massas, denominados CAD ou CAdE, apresentam, em média, uma taxa de sensibilidade de 88 a 92% e foram os primeiros tipos de CADDx a serem desenvolvidos. A taxa de falsos positivos por imagem dos sistemas para detecção de massas é mais alta que a taxa de outros tipos de sistemas CADDx.

As redes neurais artificiais Perceptron multicamadas são comumente empregadas em pesquisas de sistemas CADDx na área de classificação de nódulos, rotulando-os como malignos ou benignos. Mesmo trabalhos para detecção de massas utilizam redes neurais para diminuir o número de falsos positivos classificando as regiões de interesse encontradas em regiões verdadeiramente suspeitas ou regiões que não apresentam nenhum achado.

3. FUNDAMENTAÇÃO TEÓRICA

Conhecimentos diversos são necessários na construção de um sistema CAD. Áreas como processamento de imagens, visão computacional e inteligência artificial precisam ser aplicadas em conjunto para a construção de um sistema robusto e coerente. Nesse capítulo, são explicados conceitos e métodos utilizados tais como: o método de Marques para delimitação - segmentação - do contorno da mama (MARQUES, 2001), método de Ozekes para detecção de massas (OZEKES e OSMAN e ÇARMURCU, 2005), redes neurais artificiais, descritores de textura de Haralick (HARALICK e SHANMUGAM e DINSTEIN, 1973), momentos invariantes de Hu (HU, 1962), método de binarização de Otsu, crescimento de região e aumento de contraste logarítmico.

3.1 Método de Marques para Delimitação do Contorno da Mama

A delimitação do contorno da mama em uma imagem mamográfica é uma importante etapa na fase de segmentação da imagem. Ao separar a mama do fundo da imagem, processamentos baseados em histograma se tornam mais eficazes. Uma normalização de histograma, por exemplo, tem seu desempenho afetado negativamente se considerar todos os pixels da imagem, inclusive aqueles com valores próximos a zero que compõe o fundo das imagens mamográficas. Porém, se o histograma for calculado levando em consideração apenas os pixels que compõem a mama, o aumento de contraste na imagem é muito mais efetivo.

O presente trabalho utiliza a delimitação do contorno da mama visto no trabalho de Marques (MARQUES, 2001). Nesse método, a imagem deve ser binarizada separando os objetos, mama e outros artefatos, do fundo da imagem. Em seguida, define-se um ponto P na primeira coluna da imagem, se a mama estiver do lado esquerdo, ou na última coluna da imagem, se a mama estiver do lado direito, na metade da altura da imagem. Importante observar que, uma vez detectada em qual lado da imagem a mama se encontra, sabe-se que o ponto P pertence à região da mama. A equação (3) define matematicamente o ponto P.

$$P = \begin{cases} (0, h/2), & \text{se a mama estiver no lado esquerdo da imagem} \\ (w - 1, h/2), & \text{se a mama estiver no lado direito da imagem} \end{cases} \quad (3)$$

onde h e w são, respectivamente, a altura e largura da imagem

Em seguida, retas são traçadas a partir desse ponto variando o ângulo que cada reta faz com o eixo horizontal da imagem no intervalo de -90° até 90° , se a mama estiver no lado esquerdo da imagem, ou de 90° até 270° , se a mama estiver no lado direito da imagem. Já que o ponto P sempre pertence à mama, as retas traçadas irão, em algum momento, cruzar uma região cujos pixels possuem valor um (mama) e passar para uma região de pixels com valor zero (fundo da imagem). A equação (4) define matematicamente uma reta em função do ângulo θ .

$$f(x) = \begin{cases} x * \sin \theta + P_y, & \text{se a mama estiver no lado esquerdo da imagem} \\ (w - x) * \sin \theta + P_y, & \text{se a mama estiver no lado esquerdo da imagem} \end{cases} \quad (4)$$

Os pontos em que essa passagem acontece são registrados como vértices da mama. Como um número finito de pontos é desejado, varia-se o ângulo θ incrementando o ângulo utilizado no cálculo das retas por um passo α gerando assim um total de $180/\alpha$ retas e, portanto, $180/\alpha$ vértices. Exemplificando: se o passo escolhido para o cálculo das retas em uma imagem onde a mama está no lado esquerdo é de 3° , serão calculadas 60 retas de ângulos $\theta = -90^\circ, -87^\circ, -84^\circ, -81^\circ, \dots, 84^\circ, 87^\circ, 90^\circ$.

Ao final do método, após todas as retas serem traçadas, juntam-se todos os vértices encontrados em um polígono que representa o contorno da mama. A figura 4 ilustra as etapas mencionadas acima.




Figura 4 – Etapas do método de Marques para delimitação do contorno da mama. A imagem original (a) é binarizada e o ponto P é definido (b), em seguida são traçadas retas a partir desse ponto (c) que irão determinar os vértices que formarão o contorno da mama (d)

3.2 Método de Ozekes et al para Detecção de Massas

O algoritmo de Ozekes et al (OZEKES e OSMAN e ÇARMURCU, 2005) para detecção de massas, assim como o conceito de redes neurais artificiais, faz parte do núcleo do sistema CAD proposto. Ozekes et al utiliza *templates* para identificar quais áreas da imagem são regiões suspeitas de conter massas. O método pode ser dividido em duas partes: binarização e aplicação dos *templates*.

O algoritmo pressupõe que pixels pertencentes às massas possuirão intensidades dentro de um determinado intervalo, superiores a uma intensidade mínima e inferiores a uma intensidade máxima. O algoritmo também assume que os núcleos das massas são circulares e com um limite máximo e mínimo para o seu diâmetro. O algoritmo, então, define quatro limiares: “intensidade mínima”, “intensidade máxima”, “raio mínimo” e “raio máximo”. Um pixel só receberá o valor um na etapa de binarização se sua intensidade estiver dentro do intervalo definido por “intensidade mínima” e “intensidade máxima” e, além disso, possuir uma adjacência nas oito direções por pixels de iguais intensidades. Essa vizinhança não pode ser menor que o valor definido por “raio mínimo” nem maior que “raio máximo”.

A figura 5 mostra as vizinhanças nas oito direções e as distâncias de “raio mínimo” e “raio máximo” e a figura 6 mostra exemplos de pixels que não são considerados pertencentes ao núcleo de uma massa por não respeitar a vizinhança

de “raio mínimo” (a), por não respeitar a distância de “raio máximo” (b) e, por fim, um exemplo de pixel que respeita os quatro limiares e, portanto, pertence a um núcleo de massa (c).




Figura 5 – Vizinhanças nas oito direções a partir de um pixel central e limiares “raio mínimo” e “raio máximo” (OZEKES e OSMAN e ÇARMURCU, 2005)




Figura 6 – Pixel central não considerado pertencente a um núcleo de massa por não respeitar uma vizinhança de “raio mínimo” (a), por não respeitar uma vizinhança de “raio máximo” (b) e pixel pertencente a um núcleo de massa (c). Os pontos cinza representam pixels de intensidade dentro do intervalo aceitável (OZEKES e OSMAN e ÇARMURCU, 2005).

Após a etapa de binarização, as regiões brancas cujas formas são mais ou menos circulares representam possíveis núcleos de massas. A figura 7 mostra o resultado da binarização para uma imagem que apresenta uma região branca na parte central da imagem referente a uma massa na imagem original. A etapa de binarização também serve para reduzir a área processada na próxima parte do algoritmo. A etapa de aplicação do *template* é feita apenas no menor retângulo que

compreende os pixels brancos na imagem binarizada evitando assim processamento computacional desnecessário.




Figura 7 – Exemplo da etapa de binarização de Ozekes et al

Já que os núcleos das massas serão, supostamente, regiões brancas similares a círculos, os *template* são imagens de círculos brancos inscritos em quadrados de fundo preto. O raio do círculo determinará o raio do núcleo da massa que se quer encontrar usando o *template*. A aplicação do *template* é bastante semelhante à operação de convolução. A figura 8 mostra um exemplo de *template* com raio de dimensão 13.




Figura 8 – Exemplo de *template* com raio de tamanho igual a 13 pixels (OZEKES e OSMAN e ÇARMURCU, 2005).

A aplicação dos *templates* é semelhante à operação de convolução. A ROI definida na etapa de binarização é varrida e, para cada pixel da ROI, o pixel superior esquerdo do *template* é sobreposto a ele. São calculadas, então, duas medidas de erro: “erro de pixels pretos”, quantidade de pixels que no *template* são pretos e na imagem possuem o valor branco, e “erro de pixels brancos”, quantidade de pixels brancos no *template* que correspondem a pixels pretos na imagem. Nesta etapa, também são criados mais dois limiares: “limiar de erros pretos” e “limiar de erros brancos”.

Nesse ponto, uma nova imagem é criada para conter a marcação das massas. Quando os erros calculados entre o *template* e a janela da imagem original forem menores que os limiares definidos, todos os pixels brancos da imagem sobrepostos a pixels brancos do *template* são pintados de branco na imagem das marcações. A figura 9 mostra a aplicação do *template* a uma massa (a) e um vaso sanguíneo (c). É perceptível que os pixels acinzentados, que irão contabilizar os erros, estão mais presentes na detecção do vaso sanguíneo (d) do que na detecção da massa (b).




Figura 9 – Recorte de uma massa (a) e sua detecção pela aplicação de templates (b). Recorte de um vaso sanguíneo (c) e o resultado da aplicação do template (d) (OZEKES e OSMAN e ÇARMURCU, 2005)

Após as etapas de binarização e aplicação do *template*, as regiões brancas na imagem das marcações corresponderão a massas encontradas na imagem originais. A figura 10 mostra a aplicação do *template* na imagem binarizada mostrada na figura 7.




Figura 10 – Aplicação da binarização e templates de Ozekes et al culminando na detecção da massa presente na imagem mamográfica

Os autores do trabalho não descrevem como obtiveram os valores dos vários limiares utilizados no algoritmo o que leva a crer que os resultados expostos no trabalho foram definidos manualmente para cada imagem. O resultado mais alto obtido, ao variar o raio dos *templates* utilizados, foi o de 93% de sensibilidade com uma taxa de 1,3 falsos positivos por imagem.

3.3 Redes Neurais Artificiais

As redes neurais artificiais partem de uma abordagem biológica e fazem parte da área de inteligência artificial chamada conexionista. As redes neurais artificiais tentam modelar o cérebro humano a partir de uma rede de conexões de neurônios artificiais. Essas redes, porém, tendem a possuir um número significativamente menor de neurônios e conexões quando comparadas a um cérebro humano real (COPPIN, 2004). Apesar dessa limitação, as redes neurais possuem a habilidade de mapear sistemas não lineares, generalizando uma solução para um determinado problema a partir de amostras previamente conhecidas (SILVA e SPATTI e FLAUZINO, 2010). Em outras palavras, uma rede neural pode aprender a partir de exemplos e sugerir uma resposta para uma instância nova de um problema conhecido. Além dessa característica, as redes neurais artificiais também possuem as seguintes propriedades relevantes:

- **Organização de dados:** uma rede neural é capaz de realizar uma organização interna possibilitando o agrupamento de padrões com alguma particularidade em comum;
- **Tolerância a falhas:** por usar um grande número de neurônios e conexões na obtenção de um resultado final, as redes neurais artificiais se mostram tolerantes a falhas quando apenas uma parte de sua estrutura é corrompida;
- **Armazenamento distribuído:** o conhecimento total da rede se encontra distribuído nos diversos neurônios e sinapses que compõem a rede;
- **Facilidade de prototipagem:** uma vez treinada, a execução de uma rede neural consiste em simples operações matemáticas que, rapidamente e sem muito esforço computacional, culminam em uma resposta.

As redes neurais artificiais podem ser empregadas de várias formas diferentes e são constantemente usadas na resolução dos mais diversos problemas. São algumas de suas utilizações mais frequentes: a classificação de padrões, aproximação universal de funções, otimização de sistemas e agrupamento de dados. As redes Perceptron multicamadas são, talvez, as redes neurais que apresentam um maior número de possibilidades de aplicações (SILVA e SPATTI e FLAUZINO, 2010). Nas próximas subseções são discutidos com mais detalhes o modelo de neurônio artificial proposto por McCulloch e Pitts (MCCULLOCH e PITTS, 1943), as redes neurais Perceptron multicamadas e o algoritmo de aprendizagem *backpropagation*, todos utilizados no trabalho exposto.

3.3.1 Neurônio Artificial

O processamento de informação no cérebro humano é formado pela atuação em paralelo das várias células elementares do sistema nervoso, os neurônios. O neurônio tem a função de receber estímulos - impulsos elétricos - e conduzi-los adiante, se certas condições forem atendidas. O neurônio pode ser dividido em três partes principais: dendritos, corpo celular e axônio.

Os dendritos têm a função de captar estímulos vindo de outros neurônios ou do meio externo. O corpo celular processa a informação advinda dos dendritos e produz um potencial de ativação que determinará se um estímulo será emitido por

esse neurônio ou se ele se absterá de enviar qualquer impulso elétrico. Em caso afirmativo, o impulso elétrico é enviado pelo axônio através de terminações sinápticas para outros neurônios que estejam conectados a ele (SILVA e SPATTI e FLAUZINO, 2010). A figura 11 apresenta de forma simplificada o esquema de um neurônio biológico.




Figura 11 – Esquema de um neurônio biológico.

McCulloch e Pitts (MCCULLOCH e PITTS, 1943) propuseram um modelo de neurônio artificial baseado no neurônio biológico que, até hoje, é o mais utilizado em diferentes arquiteturas de redes neurais artificiais (SILVA e SPATTI e FLAUZINO, 2010). Nesse modelo, diversos sinais de entrada ($x_1, x_2, x_3, \dots, x_n$), são ponderados com pesos sinápticos ($w_1, w_2, w_3, \dots, w_n$) e somados. Essa soma é subtraída de um limiar de ativação (θ) produzindo o potencial de ativação (u). Se o potencial for positivo, isto é, se a soma dos sinais de entrada ponderados for maior que o limiar de ativação, o valor é passado para a função de ativação (g) e é gerado um estímulo excitatório (y). Caso contrário, a saída da função de ativação produz um estímulo inibitório. A figura 12 ilustra o modelo matemático do neurônio proposto acima.




Figura 12 – Modelo de neurônio artificial proposto por McCulloch e Pitts

Podemos representar matematicamente o funcionamento do neurônio através das equações (5) e (6).

$$u = \sum x_i w_i - \theta \quad (5)$$

$$y = g(u) \quad (6)$$

A função logística, tangente hiperbólica, onda quadrada e função linear são as funções de ativação mais comumente usadas como função de ativação. A escolha da função é feita, principalmente, pelo tipo de rede neural que se está construindo. Uma rede neural de classificação, por exemplo, utiliza em seus neurônios a função de ativação logística enquanto uma rede para aproximação funcional utiliza em seus neurônios de entrada e internos a função tangente hiperbólica e nos neurônios pertencentes às camadas de saída a função de ativação linear. A figura 13 mostra graficamente as estas funções e seus intervalos de resposta.




Figura 13 – Funções de ativação logística (a), tangente hiperbólica (b), onda quadrada (c) e linear (d).

3.3.2 Redes Perceptron Multicamadas

As redes Perceptron multicamadas - em inglês, Perceptron Multi-Layer (PML) - possuem uma ou mais camadas intermediárias de neurônios, chamadas de

camadas escondidas ou ocultas, entre a camada de entrada e a camada neural de saída. Essas redes são consideradas as mais versáteis quanto as suas aplicabilidades sendo possível atribuí-las os seguintes usos (SILVA e SPATTI e FLAUZINO, 2010):

- Reconhecimento - classificação - de padrões;
- Aproximação universal de funções;
- Identificação e controle de processos;
- Previsão de séries temporais;
- Otimização de sistemas.

Em uma rede PML, os sinais da entrada da rede são propagados pelas camadas intermediárias até culminarem na última camada neural. As saídas da primeira camada de neurônios são as entradas da segunda camada que, por sua vez, possui suas saídas ligadas as entradas da terceira camada e assim por diante. A última camada possui um neurônio para cada saída do processo que se deseja mapear. A figura 14 ilustra uma rede neural PML com duas camadas ocultas, i sinais de entrada, n_1 neurônios na primeira camada escondida, n_2 neurônios na segunda camada escondida, m neurônios na camada neural de saída e, conseqüentemente, m sinais de saída.




Figura 14 – Exemplo de PML com duas camadas ocultas

A topologia de uma PML pode variar de acordo com a complexidade do processo que se quer mapear. Em geral, testes empíricos são realizados para determinar qual o número de camadas e de neurônios que melhor apresenta resultados. Mapear um processo mais simples pode requerer um número pequeno de neurônios e camadas enquanto um processo mais complexo pode necessitar de centenas de neurônios e diversas camadas para ser mapeado com uma taxa de erro considerada aceitável.

3.3.3 Algoritmo Backpropagation e o Treinamento da Rede PML

Para o treinamento das redes PML é utilizado o algoritmo *backpropagation* ou algoritmo de retropropagação do erro. Este algoritmo de aprendizado supervisionado possui duas etapas principais: “propagação adiante” e “propagação reversa”. Na fase de “propagação adiante”, os sinais de entrada percorrem a rede normalmente e são transformados em sinais de saída. Esses sinais são comparados com as saídas esperadas e os erros de cada saída são calculados. Inicia-se, em seguida, a segunda fase do algoritmo. Os pesos sinápticos e limiares dos neurônios da camada de saída até a primeira camada neural são ajustados em função dos erros obtidos na primeira fase do algoritmo, daí o nome “propagação reversa”. O algoritmo tornou-

se popular com a publicação de Rumelhart *et al* junto com as redes PML (RUMELHART, 1986). Há variantes na literatura que, por meio de pequenas modificações, conseguiram melhorias no algoritmo como, por exemplo, na diminuição do tempo necessário para o treinamento da rede.

3.3.4 Usando Redes Neurais PML como Aproximadores Funcionais

Como dito anteriormente, as redes neurais artificiais PML também podem ser usadas como aproximadores funcionais simulando o comportamento de qualquer função real e contínua que se deseje mapear. Para isso, é necessário que os neurônios da rede utilizem uma função contínua e limitada em sua imagem como função de ativação, como as funções de tangente hiperbólica ou a função logística, e que o neurônio da camada de saída use a função linear como função de ativação (SILVA e SPATTI e FLAUZINO, 2010).

O teorema da aproximação universal, aplicado às redes PML, diz que apenas uma camada escondida de neurônios é suficiente para mapear qualquer função real e contínua, porém não faz menção ao número mínimo de neurônios necessário. O uso de mais camadas pode reduzir o tempo de treinamento da rede e possibilitar que um número menor de neurônios seja suficiente para que a rede atinja o desempenho esperado (SILVA e SPATTI e FLAUZINO, 2010).

A figura 15 mostra um exemplo da aproximação funcional feita por uma rede neural artificial para a função $y = \sin(2x) * \sin(x)$. Os valores reais da função estão representados por pontos azuis no gráfico enquanto os valores aproximados obtidos pela rede neural estão representados por pontos vermelhos.




Figura 15 – Exemplo de aproximação funcional por redes neurais artificiais (HENRIQUE, 2012)

3.4 Descritores de Textura de Haralick

A quantificação da textura de uma região pode ser importante para sua identificação. Embora não exista uma definição formal para textura, intuitivamente podem-se medir certas propriedades tais como suavidade, rugosidade e regularidade (GONZALEZ e WOODS, 2002). Haralick *et al* (HARALICK e SHANMUGAM e DINSTEIN, 1973) definem em seu trabalho 14 descritores de textura cuja finalidade é categorizar texturas diferentes entre si.

Os descritores de textura Haralick baseiam-se na assumption que a informação sobre a textura está contida nas relações espaciais que os níveis de cinza de uma imagem possuem uns com os outros. Textura e tonalidade, portanto, não podem ser avaliados de forma separada. Os autores, então, descrevem uma matriz que, supostamente, contém essas relações: a matriz de co-ocorrência. Nessa matriz estão registradas as frequências de vizinhança, usando como parâmetro uma distância d , entre os níveis de cinza da imagem nas direções vertical, horizontal e diagonal. A figura 16 ilustra os ângulos utilizados nos cálculos de cada direção.




Figura 16 – As quatro direções para o cálculo da vizinhança entre pixels

A matriz de co-ocorrência P_{ij} contém a frequência dos pontos na imagem de intensidade i que são vizinhos, a uma distância d , de pontos de intensidade j . Sua dimensão é, portanto, $n \times n$ onde n é a quantidade de níveis de cinza da imagem. A figura 17 mostra exemplos de matrizes de co-ocorrência. Importante observar que, como a vizinhança em uma direção é verificada em ambos os sentidos, a matriz é simétrica em relação a sua diagonal principal. A figura 17 trás as matrizes de co-ocorrência nas quatro direções de uma imagem usando distância $d = 1$.




Figura 17- Uma imagem 4x4 e suas matrizes de co-ocorrência não normalizadas calculadas com distância $d = 1$ e ângulos 0° (b), 90° (c), 135° (d) e 45° (e).

Para o cálculo dos descritores, é necessário normalizar a matriz de co-ocorrência. Para fazer isso, basta dividir a matriz por um fator de normalização correspondente à quantidade de vizinhanças verificadas. Na direção horizontal, ângulo igual a 0° , existem $2N_y(N_x - d)$ vizinhanças onde N_y corresponde ao número de linhas na imagem e N_x ao número de colunas. Nas direções diagonais, ângulos de 45° e 135° , há $2(N_x - 1)(N_y - 1)$ vizinhanças e na direção vertical, ângulo de 90° , $2N_x(N_y - 1)$.

Os descritores de textura são calculados usando uma matriz de co-ocorrência normalizada e alguns atributos derivados desta matriz. Como há quatro direções e, portanto, quatro matrizes, quatro valores serão obtidos para cada descritor de textura. O valor final de cada descritor é a média desses quatro valores. As equações a seguir definem os sete descritores utilizados neste trabalho. P_{ij} representa a matriz de co-ocorrência normalizada e N_g , a quantidade de níveis de cinza da imagem.

As equações (7) a (19) apresentam os descritores de Haralick usados nesse trabalho.

1. Segundo Momento Angular

$$f_1 = \sum_i \sum_j (P_{ij})^2 \quad (7)$$

2. Contraste

$$f_2 = \sum_{n=0}^{N_g-1} n^2 P_{|x-y|}(n) \quad (8)$$

onde

$$P_{|x-y|}(n) = \sum_i^{N_g} \sum_j^{N_g} P(i, j) \quad (9)$$

3. Correlação

$$f_3 = \frac{\sum_i \sum_j (ij) P(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (10)$$

onde

$$\mu_x = \sum_i i P(i, *) \quad (11)$$

$$\mu_y = \sum_j j P(*, j) \quad (12)$$

$$\sigma_x = \sqrt{\sum_i ((i - \mu_x)^2 P(i, *))} \quad (13)$$

$$\sigma_y = \sqrt{\sum_j ((j - \mu_y)^2 P(*, j))} \quad (14)$$

4. Variância

$$f_4 = \sum_i \sum_j (i - \mu_x)^2 P(i, j) \quad (15)$$

5. Momento da Diferença Inversa

$$f_5 = \sum_i \sum_j \frac{1}{1+(i-j)^2} P(i, j) \quad (16)$$

6. Média da Soma

$$f_6 = \sum_{i=2}^{2N_g} i P_{x+y}(i) \quad (17)$$

onde

$$P_{x+y}(k) = \sum_i^{N_g} \sum_j^{N_g} P(i, j), \quad k = 2, 3, \dots, 2N_g \quad (18)$$

7. Entropia

$$f_7 = - \sum_i \sum_j P(i, j) \log(P(i, j)) \quad (19)$$

3.5 Momentos Invariantes de Hu

Motivado pela necessidade de descrever figuras geométricas de duas dimensões de forma invariante às principais transformações algébricas, Hu define

sete momentos em seu trabalho de 1962 (HU, 1962). Os seis primeiros momentos definidos são invariantes a escala, translação, rotação e reflexão. O sétimo momento é variante a reflexão, o que pode ser útil na identificação de estruturas espelhadas.

As equações a seguir definem os sete momentos de Hu para uma imagem em níveis de cinza (MERCIMEK e GULEZ e MUMCU, 2005):

$$1. \quad M_1 = (\eta_{20} + \eta_{02}) \quad (20)$$

$$2. \quad M_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \quad (21)$$

$$3. \quad M_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \quad (22)$$

$$4. \quad M_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \quad (23)$$

$$5. \quad M_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\ + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \quad (24)$$

$$6. \quad M_6 = (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\ + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \quad (25)$$

$$7. \quad M_7 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\ - (\eta_{30} + 3\eta_{12})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \quad (26)$$

Onde

$$\eta_{pq} = \mu_{pq} / \mu_{00}^\gamma \quad (27)$$

$$\mu_{pq} = \sum_x \sum_y (x - \bar{x})^p * (y - \bar{y})^q f(x, y) \quad (28)$$

$$\gamma = [(p + q)/2] + 1 \quad (29)$$

$$\bar{x} = m_{10} / m_{00} \quad (30)$$

$$\bar{y} = m_{01} / m_{00} \quad (31)$$

$$m_{pq} = \sum_x \sum_y x^p y^q f(x, y) \quad (32)$$

3.6 Binarização de Otsu

O método de Otsu (OTSU, 1979) é considerado um eficiente método de binarização automática de imagens. O método assume que a imagem está dividida em duas classes, objeto e fundo, e tenta encontrar o limiar que melhor divide essas classes por meio de múltiplas iterações. Para isso, calcula-se a variância entre as classes de objeto e fundo para todos os possíveis limiares. O limiar que possuir maior variância inter-classe é o limiar escolhido pelo método. Segundo o artigo de Otsu, maximizar a variância inter-classe é o mesmo que minimizar a variância intra-classe, definida como a soma ponderada entre as variâncias das duas classes.

Uma vez definido, todos os pixels da imagem cujos valores de nível de cinza são inferiores ao limiar escolhido são pintados de pretos e, conseqüentemente, aqueles cujos valores de nível de cinza superarem ou igualarem o limiar são pintados de branco. A figura 18 mostra um exemplo de imagem binarizada pelo método de Otsu.



Figura 18 – Exemplo de binarização pelo método de Otsu

3.7 Crescimento de Região

O algoritmo de crescimento de regiões tem como objetivo a partição da imagem em áreas de interesse. É necessário definir um ponto inicial denominado “semente” que faça parte da área a ser segmentada. A região é primeiramente

composta por este ponto. Em seguida, é feita uma verificação nos pontos que compõem a vizinhança dessa semente: se esses pontos obedecem a um critério de seleção, eles são também inseridos no conjunto de pontos que formam a região e o processo de verificação da vizinhança se repete para os novos pontos adicionados. Isso é feito até que nenhum ponto verificado obedeça ao critério escolhido (GONZALES, 2002). Nota-se que o algoritmo não segmenta regiões descontínuas, mesmo que estas obedeçam aos critérios escolhidos.

O critério que determina se um ponto faz parte ou não de uma região é normalmente o seu nível de cinza. Se o valor for superior a um limiar definido, o critério é obedecido e o ponto é considerado como pertencente à região. A figura 19 mostra dois exemplos de aplicação do algoritmo a uma imagem variando o limiar utilizado.



Figura 19 - Massa mamográfica (a) segmentada com limiar de 40.040 (b) e com limiar de 54.600 (c)

3.8 Aumento de Contraste Logarítmico

O aumento de contraste logarítmico, ou transformação logarítmica, consiste na aplicação da função logarítmica nos pixels da imagem seguida por uma normalização de histograma (GONZALEZ e WOODS, 2002). A equação (33) mostra a fórmula da transformação onde $f(x, y)$ é a função da imagem original e $f'(x, y)$ a função da imagem após o contraste.

$$f'(x, y) = c \log(1 + f(x, y)) \quad (33)$$

Ao aplicar o contraste logarítmico em uma imagem, os pixels de baixa intensidade tem seu histograma expandido para uma faixa maior do histograma, deixando a imagem mais clara e comprimindo os níveis mais altos do histograma da

imagem original. Essa transformação é muito usada na visualização de imagens no domínio da frequência. A figura 20 mostra a aplicação do contraste logarítmico em uma imagem mamográfica.




Figura 20 – Aplicação do aumento de contraste logarítmico em uma imagem mamográfica

3.9 Sumário

Técnicas e algoritmos utilizados no trabalho foram descritos neste capítulo. A delimitação do contorno da mama de Marques e a detecção de massas de Ozekes compõem os principais tópicos em visão computacional utilizados neste trabalho. O primeiro se baseia na binarização da imagem mamográfica e, em seguida, na delimitação de retas que, ao passar de uma região branca para uma região preta, definem os vértices que irão compor o contorno da mama. A detecção de massas de Ozekes binariza a imagem, utilizando quatro parâmetros, e identifica as regiões segmentadas que mais se assemelham a massas por meio de *templates*, utilizando mais dois parâmetros no processo.

Também foram definidas as redes neurais artificiais, abordagem de inteligência artificial considerada conexionista que utiliza analogias biológicas, em específico do sistema nervoso, na construção de redes que mapeiam conhecimentos. Foi dada uma breve explicação sobre o seu funcionamento e as possibilidades de seus usos.

Apresentaram-se também os atributos de imagens usados nesse trabalho: descritores de textura de Haralick e momentos invariantes de Hu. Os descritores de

textura de Haralick servem para quantificar a textura de imagens medindo, mesmo que indiretamente, atributos como suavidade, rugosidade e regularidade. Já os momentos invariantes de Hu são mais usados para descrever formas geométricas e são invariantes à maioria das operações algébricas como rotação, escala e deslocamento.

Por fim, os algoritmos de binarização de Otsu, crescimento de região e aumento de contraste logarítmico, usados em diversas partes desse trabalho, também foram descritos nesse capítulo.

4. MATERIAIS E MÉTODOS

Aplicando manualmente o método de Ozekes (OZEKES e OSMAN e ÇARMURCU, 2005) nas 120 imagens de teste usadas nesse trabalho, foi possível detectar a massa presente em 99% dos casos. Isso mostra que, com a calibração certa de seus parâmetros, o método de Ozekes consegue taxas próximas a 100% de sensibilidade. Porém, o método possui sete parâmetros necessários ao seu funcionamento. Como dito anteriormente, o ajuste desses parâmetros de forma manual é trabalhoso e impraticável para profissionais da saúde.

Durante o desenvolvimento da pesquisa, diversos valores para os parâmetros do método de Ozekes foram experimentados com o objetivo de avaliar se todos os parâmetros eram mesmo necessários. Por fim, descobriu-se que uma binarização global simples, usando um único limiar de intensidade, era suficiente para binarizar corretamente todas as imagens usadas nos testes. Além disso, simplificou-se também a etapa de *templates*: ao invés de dois limiares de erro, utilizou-se apenas uma medida que contabiliza os pixels de valor diferente entre o *template* e a região da imagem que ele está sobreposto, não fazendo discriminação entre “erros de pixels brancos” e “erros de pixels pretos”. O parâmetro de raio do *template* continua sendo usado normalmente. Também se experimentou calcular a diferença absoluta entre as regiões da imagem e do *template* atribuindo as intensidades encontradas aos pixels de uma nova imagem. Essa abordagem, semelhante à técnica de filtragem casada, produz uma imagem em tons de cinza cujos pontos de maior brilho referem-se aos locais da imagem que são mais semelhantes ao *template* usado. A aplicação de um limiar na imagem resultante após esse processamento indica quais pontos devem ser considerados como pertencentes a uma possível massa.

Em síntese, o método proposto é uma simplificação do algoritmo de Ozekes que não necessita de ajustes manuais em seus parâmetros. Binariza-se a imagem fazendo com que a massa que se deseja detectar seja destacada como objeto da imagem e, em seguida, aplica-se um *template* para detectar apenas regiões aproximadamente circulares, excluindo estruturas como vasos sanguíneos e fibras que erroneamente foram segmentadas na fase de binarização.

As próximas seções descreverão os materiais, softwares, bibliotecas, banco de imagens, a arquitetura do sistema proposto e o treinamento das redes neurais artificiais usados nesse trabalho.

4.1 Materiais

Nesta seção é descrito o ImageJ, software que serviu como base para construção dos módulos de processamento de imagens e visão computacional; o framework de redes neurais Encog e o banco de imagens mamográficas DDSM, de onde foram retiradas as 120 imagens usadas nos testes desse trabalho.

4.1.1 Software de Processamento de Imagens ImageJ

O ImageJ (IMAGEJ, 2011) é um software de domínio público voltado para o processamento e análise de imagens baseado no software NIH para Macintosh (FERREIRA, 2011). O ImageJ é codificado em Java e, portanto, roda em qualquer computador com máquina virtual Java 1.5 ou superior. Ele permite abrir, editar, processar e analisar imagens de 8, 16 ou 32 bits nos formatos TIFF, GIF, JPEG, BMP, DICOM, FITS e imagens 'raw'. O ImageJ executa seus processamentos em *multithread* permitindo que mais de uma operação seja feita simultaneamente.

Sua arquitetura aberta permite a extensão de suas funcionalidades através de *plug-ins* que podem ser criados e editados na própria interface do programa ou por meio de um editor de texto qualquer. Para instalar um *plug-in* no ImageJ, basta copiar os arquivos de extensão *.class* gerados após a compilação dos arquivos de extensão *.java* para a pasta */plug-ins* no diretório raiz do ImageJ. Uma vez instalados, os *plug-ins* aparecerão como itens do menu Plugins. A possibilidade de desenvolver e adicionar *plug-ins*, aliada à capacidade de manipulação de diferentes tipos de imagens, torna o ImageJ uma rápida ferramenta para prototipação e desenvolvimento de sistemas de processamento de imagens digitais.

É possível usar o ImageJ como um programa *stand-alone* ou como uma biblioteca, aproveitando suas operações de manipulação e processamento de imagens. Nesse caso, basta adicionar a referência do JAR executável do ImageJ ao projeto em questão. As funcionalidades apresentadas nesse trabalho foram desenvolvidas como *plug-ins* para o ImageJ versão 1.42. A figura 21 mostra a interface padrão do ImageJ usado como um programa *stand-alone*.




Figura 21 – Captura de tela do ImageJ mostrando os plugins

4.1.2 Framework de Redes Neurais Encog

Encog é um framework de redes neurais artificiais e outros mecanismos de aprendizado de máquina disponível em Java e .NET e desenvolvido por Jeff Heaton, autor de diversos livros sobre o tema (ENCOG, 2012). O framework possibilita a construção de redes neurais dos mais diversos tipos permitindo escolhas referentes ao algoritmo de aprendizagem utilizado, arquitetura da rede neural, função de ativação dos neurônios e suporte a diversos modelos de dados para treinamento.

Em desenvolvimento ativo desde 2008, o framework Encog também possibilita o uso de *multithread* - caso a máquina hospedeira suporte – e uso de processadores gráficos com o objetivo de reduzir o tempo de processamento no treinamento das redes. Nesse trabalho, foi utilizado a versão 3.0.1 da biblioteca.

4.1.3 Banco de Imagens DDSM

O banco de imagens utilizado no trabalho é o Digital Database for Screening Mammography (DDSM). O DDSM possui 2620 casos de exames mamográficos, cada caso contendo uma imagem de incidência crânio-caudal esquerda e direita e uma imagem de incidência médio-lateral esquerda e direita, resultando em 10480 imagens mamográficas (HEATH *et al*, 2001). Cada caso possui informações sobre o scanner usado no processo de digitalização das imagens, classificação – normal,

benigno sem retorno, benigno ou maligno - do caso com a classificação BI-RADS® (ACR, 2003) e o contorno do achado radiográfico, caso a imagem o possua, definido por no mínimo dois especialistas.

Além disso, também seguindo o padrão BI-RADS® terceira edição, cada caso possui informação sobre a densidade mamária da paciente. As densidades são classificadas em quatro categorias, numeradas de um a quatro:

1. *Almost entirely fat*: menos de 25% da mama é composto por tecido glandular.
2. *Scattered fibroglandular densities*: 25% a 50% da mama é composto por tecido fibroglandular.
3. *Heterogeneously dense*: 51% a 75% da mama composto por tecido fibroglandular.
4. *Extremely dense*: mais que 75% da mama é composto por tecido fibroglandular.

Utilizou-se nesse trabalho 120 imagens do banco DDSM contendo achados radiográficos de massas, malignos e benignos. Foram escolhidas 30 imagens de cada densidade mamária, informação contida nas anotações dos casos do DDSM.

4.2 Arquitetura do Sistema CADDx Proposto

Para uma melhor organização, o sistema proposto foi dividido em etapas. Cada uma delas foi desenvolvida como um ou mais *plug-ins* para o ImageJ. Isso permite que cada etapa seja vista como um módulo isolado, permitindo que outros desenvolvedores de sistemas CADDx os utilizem em seus trabalhos sendo apenas necessária a adição do ImageJ como uma biblioteca Java em seus projetos.

A primeira etapa de pré-processamento retira as bordas presentes em algumas imagens mamográficas, ruído muito comum resultado de uma má digitalização das imagens. A seguir, a imagem passa pela etapa de segmentação onde são definidos os contornos da mama e do músculo peitoral.

Após a primeira definição de contorno, a mama é recortada da imagem e redimensionada para uma largura fixa de 600 pixels. Isso reduz o custo computacional das operações seguintes sem comprometer a visibilidade das massas. Em todos os testes, as massas ainda eram visíveis após essa redução de tamanho nas imagens. Uma vez reduzida, é necessário que a etapa de

segmentação seja aplicada novamente sobre a imagem para que se obtenha o contorno da mama e do músculo peitoral, agora reduzidos.

Após a etapa de segmentação, é aplicada uma etapa de aumento de contraste e redução de ruído na imagem. Foram testadas três opções distintas para essa fase: expansão de histograma com percentil de 1%, equalização de histograma e aumento de contraste logarítmico seguido de expansão de histograma. Após o aumento de contraste é aplicado um filtro da mediana para redução de ruído.

Após o processamento da imagem, atributos estatísticos, descritores de Haralick e momentos invariantes de Hu são extraídos e usados como entrada para a primeira rede neural. A computação dessa rede produz o limiar que será usado para binarizar a imagem. Após isso, mais seis atributos são extraídos, dessa vez da imagem binarizada: área da mama, quantidade de pixels segmentados, quantidade de regiões segmentadas, raio médio das regiões, desvio padrão dos raios e a razão entre pixels segmentados e a área da mama. Esses novos atributos são passados para a segunda rede neural que produzirá o raio que será usado na segunda etapa do método proposto, a aplicação do *template*.

Em diversos momentos, é necessário que se saiba a localização da mama na imagem – lado direito ou lado esquerdo – e se a imagem é de incidência médio-lateral ou crânio-caudal. Para determinar o lado em que a mama se encontra, calculou-se o valor médio dos pixels do lado direito e esquerdo da imagem. O lado em que o valor da média é maior é o lado em que a mama está localizada. Para saber se a imagem é de incidência crânio-caudal ou médio lateral, pode-se olhar para o nome do arquivo da imagem: se a cadeia de caracteres “CC” é encontrada, a imagem é de incidência crânio-caudal, porém, se a cadeia de caracteres “ML” é encontrada, a imagem é de incidência médio-lateral.

Após a definição de todas as etapas do sistema proposto, percebe-se que, em nenhum momento, a interferência do usuário é requisitada. O sistema pode ser considerado como automático, bastando para isso que as imagens de entrada do sistema sejam corretamente nomeadas para que não haja necessidade de perguntar ao usuário se a imagem é de incidência crânio-caudal ou médio lateral.

A figura 22 mostra um esquema sequencial das etapas do método proposto. Nas próximas seções será detalhada cada etapa.



Figura 22 – Esquema mostrando as etapas do sistema

4.1.1 Pré-Processamento: Remoção das Bordas da Imagem

Em algumas imagens mamográficas digitalizadas, há o aparecimento de bordas brancas retangulares, como vistas na figura 23. Isso acontece devido a um mau posicionamento da chapa radiográfica no digitalizador. Embora essas bordas não afetem a qualidade da imagem, elas podem interferir no resultado de alguns algoritmos de segmentação. Como as bordas são bem características e não apresentam muita variação, desenvolveu-se um algoritmo *ad hoc* para sua eliminação.




Figura 23 – Exemplos de imagens digitalizadas apresentando bordas brancas

Primeiro, aplica-se um aumento de contraste por equalização de histograma na imagem. Importante lembrar que esse pré-processamento é feito globalmente e apenas para essa etapa de remoção de bordas. Após essa etapa, a imagem é retornada ao seu contraste original.

Após a aplicação da equalização, varrem-se as beiradas da imagem até uma distância igual a 10% da altura total da imagem. O algoritmo de crescimento de região é aplicado a qualquer pixel cujo valor seja igual ou superior a 64.000 que, após a equalização de histograma, em todos os casos testados, correspondem a pixels pertencentes às bordas brancas da imagem. O próximo passo consiste em recortar a imagem para remoção das bordas sem comprometer a área da mama. É feito outra varredura, nas direções horizontal e vertical, partindo do centro da imagem até suas beiradas. Ao encontrar o primeiro ponto pertencente a uma borda

branca, a imagem é cortada. Deve-se tomar cuidado para evitar as extremidades da imagem, canto superior esquerdo e direito e cantos inferior esquerdo e direito. Para isso, evita-se uma área retangular nas primeiras e últimas colunas da imagem com largura igual a 10% da altura total da imagem, na verificação vertical, e uma área de largura também igual a 10% da altura da imagem nas primeiras e últimas linhas na varredura horizontal. Se este cuidado não for tomado e se uma borda presente na lateral da imagem se funde a uma borda da parte inferior ou superior, o algoritmo se confunde e acaba cortando a imagem de maneira errada.

A figura 24 ilustra passo a passo a aplicação do algoritmo em uma imagem com dimensões 3466 x 6871 pixels. Todos os pontos distantes até 687 pixels da borda são examinados à procura de sementes para o algoritmo de crescimento de região como mostram as regiões em vermelho da figura 24.b. Após a identificação das regiões brancas, são feitas varreduras horizontais e verticais para identificar quais os limites da borda esquerda (c), direita (d), superior (e) e inferior (f) definirão a área a ser cortada (g) da imagem original (a) resultando em uma imagem sem as bordas brancas (h).




Figura 24 – Passos do algoritmo para remoção das bordas brancas

4.2.2 Segmentação

Na etapa de segmentação, delimita-se o contorno da mama e do músculo peitoral segmentando a imagem em mama, músculo e fundo da imagem. O método de Marques (MARQUES, 2001) foi utilizado para delimitar o contorno da mama. Para evitar uma binarização manual da imagem, utilizou-se o aumento de contraste logarítmico (GONZALEZ e WOODS, 2002) seguido da binarização automática de Otsu (OTSU, 1979). Esse procedimento permite binarizar de forma automática e correta a imagem separando os objetos - mama e artefatos - do fundo da imagem. Após a etapa de binarização, o método de Marques é aplicado normalmente e o contorno da mama é obtido. A figura 25 mostra as etapas de binarização e o contorno da mama obtido.




Figura 25 – Imagem original (a), imagem após o aumento de contraste logarítmico (b), binarização de Otsu (c) e delimitação do contorno de Marques (d)

Para detecção do músculo peitoral nas imagens de incidência médio-lateral, utilizou-se uma versão do método de Marques descrita no artigo de Barbosa Filho (BARBOSA FILHO, 2011). Nesse artigo, utiliza-se o recorte automático de uma ROI que se sabe conter parte do músculo peitoral. A partir dessa ROI, o limiar que será usado para binarizar a imagem original em músculo e outros tecidos da mama é extraído. Após a binarização da imagem usando esse limiar, o método de Marques (MARQUES, 2001) é aplicado.

O recorte automático de uma ROI contendo o músculo peitoral pode ser visto no artigo de Karssemeijer *et al* (KARSSEMEIJER *et al*, 1998) e posteriormente em outros artigos da literatura como os artigos de Ferrari *et al* (FERRARI *et al*, 2000; FERRARI *et al*, 2004). O recorte é feito a partir da definição de cinco pontos no contorno da mama: pontos A, B, C, D e E. O ponto A é o ponto superior esquerdo, caso a mama esteja localizada no lado esquerdo da imagem, ou o ponto superior direito da imagem se a mama estiver localizada no lado direito. O ponto B também está localizado na parte superior da imagem e marca o limite entre a mama e o fundo da imagem. O ponto C também marca o limite entre mama e fundo da imagem, porém situa-se nos quadrantes inferiores. Define-se também o ponto D, que é o ponto médio entre o ponto A e o ponto C. Por fim, o ponto E é o ponto de encontro de retas horizontais e verticais partindo dos pontos D e B. Dessa forma, a região de interesse que contém o músculo peitoral é um retângulo definido pelos pontos A, B, D e E como visto na Figura 26.




Figura 26 – Pontos que demarcam a região de interesse contendo o músculo peitoral

Após o recorte da ROI, aplica-se o filtro da mediana com dimensões 5x5 para diminuição do ruído. Em seguida, a binarização de Otsu é aplicada à ROI que contém o músculo peitoral. O limiar obtido supostamente consegue dividir na imagem os tecidos pertencentes ao músculo peitoral do restante da mama. Esse limiar é usado para binarizar a imagem original que, após essa operação, deverá apresentar o músculo peitoral como uma única grande região branca e contínua.

O método de Marques (MARQUES, 2001) é aplicado novamente só que, ao invés de definir o ponto P na metade da imagem, define-se agora o ponto de onde serão traçadas as retas do método como o ponto superior direito ou esquerdo, dependendo de onde a mama está localizada. Isto se deve à localização do músculo peitoral nas imagens. A figura 27 mostra as etapas do método para delimitação do músculo: imagem original (a), recorte da ROI contendo o músculo e aplicação do filtro da mediana (b), aplicação do método de Otsu na ROI (c), binarização da imagem original usando o limiar obtido na etapa anterior (d), retas traçadas a partir do ponto P (e) e o contorno do músculo definido (f).




Figura 27 – Etapas do método para delimitação do músculo peitoral

4.2.3 Recorte e Redimensionamento da Mama

Após a segmentação e delimitação do contorno da mama e do músculo peitoral, a mama é recortada e a imagem resultante é redimensionada para 600 pixels de largura. Isso é feito para diminuir o custo computacional e o tempo de processamento das etapas seguintes. Verificou-se que todas as massas continuavam visíveis e detectáveis pelo método proposto mesmo após essa redução de tamanho. Resoluções menores não foram testadas já que, na configuração escolhida, o tempo de processamento da extração dos atributos e aplicação dos *templates* nas imagens não ultrapassa a escala de segundos - a máquina usada nos testes possui processador Core 2 Duo de 1,50 Ghz e 2 GB de memória RAM.

Após a redução da imagem, a etapa de segmentação é novamente aplicada para obtenção do novo contorno da mama e do músculo peitoral.

4.2.4 Pré-Processamento: Aumento de Contraste e Redução de Ruído

Após a redução e nova segmentação da imagem, é aplicada uma operação de aumento de contraste. Foram testados os algoritmos de expansão de histograma com percentil de 1%, equalização de histograma e aumento de contraste logarítmico seguido da expansão de histograma. Todos os três algoritmos levam em conta apenas à área da mama segmentada anteriormente excluindo o músculo peitoral nas imagens de incidência crânio-caudal e o fundo da imagem. Após a aplicação do algoritmo de aumento de contraste, é aplicado um filtro da mediana usando uma janela 11x11 na imagem para diminuir o ruído, evitando uma segmentação

excessiva na etapa de binarização. A utilização de raios maiores na aplicação da mediana ocasionava, as vezes, na fusão de estruturas da mama com as massas, dificultando ou impedindo sua detecção.

O desempenho do sistema foi avaliado para cada algoritmo separadamente. A figura 28 mostra os três tipos de pré-processamentos aplicados a uma imagem mamográfica em adição ao filtro da mediana.




Figura 28 – Imagem original (a), expansão de histograma com percentil de 1% (b), equalização de histograma (c) e aumento de contraste logarítmico seguido de expansão de histograma (d).

4.2.5 Extração de Atributos da Imagem

Após o pré-processamento, são extraídos atributos da imagem. Considerando apenas a área da mama e excluindo o músculo peitoral, quando houver, são calculados a entropia e os chamados momentos centrais: média, variância, obliquidade e curtose da imagem. Também são calculados os sete momentos invariantes de Hu e sete descritores de Haralick: segundo momento angular, contraste, correlação, variância, momento da diferença inversa, média da soma e entropia.

Na construção do sistema, são definidos quais atributos serão usados como entrada para as redes neurais por meio de testes empíricos. Por conta dessa seleção, na execução do sistema, apenas os atributos escolhidos precisam ser extraídos das imagens. Na seção 4.5 é explicado detalhadamente como se dá o processo de seleção de atributos.

4.2.6 Cálculo do Limiar da Binarização

Os atributos extraídos da imagem são passados como entrada para a primeira rede neural. Faz-se, então, a computação dessa rede: uma série de somas e ponderações de suas entradas. O resultado é um valor numérico que será usado como limiar para a próxima etapa do sistema.

4.2.7 Binarização da Imagem

Com o limiar calculado anteriormente, binariza-se a imagem. Todos os pixels da imagem que possuírem o valor de intensidade inferior ao limiar são atribuídos ao valor zero e todos os pixels de intensidade igual ou maior ao limiar recebem o valor máximo de um. A figura 28 mostra um exemplo de binarização de uma mamografia.




Figura 29 – Exemplo de imagem original (a) e a pós o processo de binarização (b)

4.2.8 Extração de Atributos da Imagem Binarizada

Nesse caso, atributos são extraídos da imagem, agora binária, para servirem de entrada para a segunda rede neural. Seis medidas são calculadas: a área da mama, a quantidade de pixels segmentados, a quantidade de regiões segmentadas, o raio médio dessas regiões - assumindo que suas áreas correspondem a círculos -, o desvio padrão desses raios e a razão entre pixels segmentados e a área da mama.

4.2.9 Cálculo do Raio do Template

Similar ao cálculo do limiar usado na etapa de binarização, os atributos extraídos na etapa anterior são passados para a segunda rede neural, obtendo-se o raio que será usado na etapa posterior.

4.2.10 Aplicação do Template

Dois métodos diferentes de aplicação dos *templates* foram experimentados. O primeiro assemelha-se à aplicação de *template* do método de Ozekes, diferindo apenas no limiar de erro usado. Ao invés de usar duas medidas de erros, “erro de pixels brancos” e “erro de pixels pretos”, usa-se uma só medida de erro que indica a quantidade de pixels de valor diferente entre o *template* e a região da imagem que está sendo verificada. O limiar é dado como uma porcentagem em relação à área do

template. Por exemplo, se o limiar adotado é de 75% e o *template* possui dimensão 10x10, 75 pixels devem ter valores iguais entre o *template* e a região da imagem que está sendo verificada para que seus pixels possam ser considerados pertencentes a uma massa. Em caso positivo, semelhante ao algoritmo original de Ozekes, os pixels da imagem sobrepostos aos pixels brancos do *template* também são pintados de branco. A figura 29 mostra a imagem binária e o resultado após a aplicação de um *template*: uma segunda imagem também binária com as marcações das supostas massas.




Figura 30 – Imagem binarizada (a) e resultado após a aplicação dos templates (b)

O segundo método testado de aplicação de *templates* envolve calcular a diferença absoluta entre os pixels do *template* e da região verificada na imagem. Em seguida, essa diferença é dividida pela área total do *template*. O resultado é semelhante à técnica de filtro casado: os pontos da imagem pertencentes a áreas mais parecidas com o *template* resultarão em pontos de intenso brilho após o processamento. Importante observar que, nesse método, o resultado da aplicação do *template* com a imagem binária resulta em uma imagem em tons de cinza, assim como na técnica do filtro casado. Nesse trabalho, normalizou-se a imagem resultante para 8 bits. A intensidade dos pixels das imagens resultantes desse segundo método de aplicação do *templates*, portanto, varia de 0 a 255.

Depois desse processamento, pinta-se um pequeno círculo de 20 pixels de diâmetro nos pontos acima de um determinado limiar para fazer a marcação das massas encontradas e, conseqüentemente, transformando a imagem novamente em

binária. O desenho de círculos, nos pontos cuja intensidade ultrapassou o limiar adotado, ou seja, onde houve uma detecção, evita que pixels muito próximos entre si, mas não vizinhos, sejam considerados como diferentes massas no final do processo, fundindo-os em uma única marcação. A figura 30 mostra a aplicação dos *templates*, de acordo com essa abordagem, seguida das marcações feitas nos pontos acima do limiar estabelecido.




Figura 31 – Imagem binária resultante da etapa de binarização (a), imagem após a aplicação dos *templates* novamente em níveis de cinza (b) e resultado das marcações feitas após a aplicação do limiar transformando a imagem novamente em binária (c)

A equação 34 define o cálculo realizado na aplicação do *template*, segundo essa abordagem, onde f é a imagem binarizada, w o *template* circular, n o número de pixels no *template* e f' a imagem após a aplicação do *template*.

$$f'(x, y) = \sum_s \sum_t [255 - |f(x + s, y + t) - w(s, t)| / n] \quad (34)$$

4.3 Configuração das Redes Neurais

Como dito anteriormente, para que uma rede neural Perceptron multicamada funcione como um aproximador universal de funções, é necessário que os neurônios das camadas escondidas possuam uma função de ativação contínua e limitada em suas imagens e que a camada de saída da rede possua como função de ativação a

função linear. Nesse trabalho, foi utilizada a função logística nos neurônios das camadas ocultas da rede e a função linear no neurônio de saída.

Em todos os testes, a matriz de pesos sinápticos da rede era iniciada com valores aleatórios dentro do intervalo $(-2,4/N \leq W_{ij} \leq 2,4/N)$ onde N é o número de entradas da rede e W_{ij} o peso sináptico do neurônio i na camada j . Segundo orientações de Silva et al. (2010), isso evita que a soma ponderada das entradas sature as funções de ativação, o que pode afetar o desempenho da rede.

4.4 Treinamento das Redes Neurais

O aprendizado das redes neurais Perceptron multicamadas se dá de forma supervisionada, isto é, é necessário que exemplos de entradas e suas respectivas saídas sejam passados para a rede neural para que, por meio de um algoritmo, seus pesos sinápticos sejam ajustados de forma a generalizar o problema desejado.

Para isso, aplicou-se o método proposto nas 120 imagens de testes pré-processadas, definindo manualmente os melhores valores dos parâmetros para cada imagem de forma a detectar a massa existente em cada caso com o menor número de falsos positivos possíveis. Os argumentos, limiar da binarização e raio do template, são anotados e, junto com os atributos extraídos das imagens, gravados em um arquivo SNNS (Stuttgart Neural Network Simulator), formato de arquivo utilizado em diversos programas e bibliotecas de redes neurais. Esse arquivo é passado como entrada para o algoritmo de treinamento da rede. No treinamento da primeira rede neural, os atributos da imagem da mama são usados como entrada em conjunto com o limiar da binarização, saída desejada da rede. Já na segunda rede neural, os atributos referentes à imagem já binarizada são considerados como entrada da rede enquanto o raio do template, previamente anotado, é a saída. O limiar usado na etapa de aplicação de templates é variado arbitrariamente para construção das curvas FROC do sistema.

Importante lembrar que, por usar a função sigmóide como função de ativação, os atributos de entrada são normalizados para que seus valores fiquem dentro do intervalo $[-1,1]$ e as saídas normalizadas para o intervalo $[0,1]$.

Foi escolhido o método de propagação resiliente *resilient-propagation*, variação do *backpropagation* para treinamento das redes por ajustar dinamicamente a taxa de aprendizado do algoritmo. Utilizou-se um limite de 500 ciclos para o treinamento das redes neurais. O aumento no número de ciclos não mostrou

diminuição significativa no tempo de convergência da rede ou na diminuição do erro gerado.

Utiliza-se o método de teste de validação cruzada *leave-one-out* para evitar que uma mesma imagem seja utilizada ao mesmo tempo no treinamento e validação de uma rede neural. São executadas 120 rodadas de teste e, em cada rodada, utiliza-se 119 imagens para treinamento e a imagem restante para validação da rede e obtenção do erro. O erro final de uma rede é calculado como a média aritmética dos erros de todas as 120 rodadas de treinamento e validação.

4.5 Seleção de Atributos e Topologia da Rede

A escolha da topologia e a seleção de atributos é uma etapa muito importante na obtenção de bons resultados em uma rede neural. Devido à grande quantidade de opções, os atributos e topologia da rede usada na etapa de binarização foram selecionados empiricamente. A rede neural usada no cálculo do raio dos templates possui poucos atributos disponíveis e, portanto, todos foram usados no seu treinamento, tendo apenas sua topologia decidida empiricamente.

Foram estudados três grupos de atributos de imagem para a primeira rede neural: momentos centrais – média, variância, obliquidade e curtose – mais a entropia da imagem, descritores de textura de Haralick e momentos invariantes de Hu. Para cada permutação desses grupos, dez redes neurais de uma camada escondida com número variável de neurônios são treinadas e o erro médio gerado por essas redes é calculado. Esse processo é repetido para cada um dos três algoritmos usados na fase de pré-processamento do sistema. O pensamento que motiva essas verificações é que é possível que um determinado conjunto de atributos seja a melhor solução quando um algoritmo específico de aumento de contraste é usado e não o seja para os demais algoritmos. Portanto, faz-se necessário testar todas as combinações de conjunto de atributos e algoritmos usados no pré-processamento. O uso de redes com diferentes topologias nos testes impede que um determinado conjunto de atributo se sobressaia aos demais pela adequação a um número específico de neurônios na camada escondida. Variando o número de neurônios têm-se um resultado mais justo na escolha dos atributos.

Analogamente, é possível que o parâmetro distância, usado no cálculo dos descritores de Haralick, também tenha seu melhor valor variável dependendo de

quais atributos se use em conjunto com os descritores. Por causa disso, em todo teste envolvendo os descritores de Haralick, também foi verificado o erro médio para diferentes distâncias, em específico, variando o valor da distância de um até 200.

A figura 31 ilustra o processo de escolha da melhor distância para o cálculo dos descritores de Haralick em forma de tabela e de gráfico, usados para uma melhor visualização dos resultados. A tabela mostra o erro médio para redes com diferentes números de neurônios, eixo vertical, quando usado um determinado conjunto de atributos contendo descritores de Haralick calculados com diferentes distâncias, eixo horizontal da tabela. O erro médio de todas as topologias para cada distância, calculado e exibido na parte inferior da tabela, é usado para traçar o gráfico na parte inferior da figura que ajuda na visualização do padrão distância x erro.




Figura 32 – Processo de escolha da distância no cálculo dos descritores de Haralick para um conjunto de atributos.

A figura 32 mostra o processo de seleção do melhor conjunto de atributos. Após decidir quais distâncias serão usadas no cálculo dos descritores de Haralick para diferentes conjuntos de atributos, o erro médio para diferentes topologias

também é calculado para os conjuntos que não possuem os descritores. Depois, todos os valores são comparados para determinar qual conjunto de atributos, incluindo a distância que se deve usar no cálculo dos descritores de Haralick, que obtém o menor erro quando usado como entrada para a primeira rede neural.




Figura 33 – Escolha do melhor conjunto de atributos a serem usados como entrada para a primeira rede neural.

Após decidir qual conjunto de atributos será usado no treinamento, a topologia da rede neural deve ser escolhida. Para isso, foram realizados testes envolvendo redes com uma, duas e três camadas escondidas com o mesmo número de neurônios por camada variando de acordo com o número de entradas da rede. Além disso, também eram testadas topologias com duas camadas escondidas, com a segunda camada contendo um número pequeno, relativo à entrada, e fixo de neurônios, topologias que são bastante comuns na literatura.

O número de neurônios utilizado nesses testes varia de acordo com o comportamento observado nos testes para seleção de atributos: neles, é possível ver o comportamento que as redes apresentam em relação ao número de neurônios usados por camada e quais os limites que devem ser verificados para o descobrimento do número ótimo de neurônios por rede.

4.6 Avaliação da Detecção e Geração das Curvas FROC

Após decidir quais atributos e topologias serão usados nas redes neurais para cada um dos algoritmos de pré-processamento testados, treinam-se as redes com as configurações escolhidas e aplica-se o algoritmo de detecção nas imagens: binarização seguido da aplicação dos templates com raios definidos pela computação das redes neurais. Todo processo de treinamento utiliza a estratégia de validação cruzada *leave-one-out*.

Para gerar as curvas FROC, variam-se os limiares da etapa de aplicação de templates. O limiar do primeiro método de aplicação dos templates corresponde à quantidade de pixels que deve ser igual entre o template e a região da imagem verificada enquanto no segundo método testado o limiar corresponde ao nível de cinza da imagem após a operação de aplicação dos templates, similar ao processamento por filtro casado. Os pontos de operação das curvas foram obtidos usando os valores 65%, 70%, 75%, 80% e 85% para o limiar do primeiro método e 140, 150, 160, 170 e 180 para o limiar do segundo método de aplicação dos templates.

Para calcular a taxa de sensibilidade e falsos positivos, é aplicado o algoritmo de crescimento de região nas imagens ao término do processamento. Com isso, as marcações feitas pelo sistema são identificadas e é possível verificar se a detecção foi bem-sucedida, caso haja interseção entre alguma marcação e o gabarito da imagem em questão. O banco de imagens usado possui marcações feitas por especialistas, funcionando como um gabarito.

Especificamente quando usado o primeiro método de aplicação de templates, é necessário que a intersecção entre a marcação e o gabarito seja superior a 30%. Esse valor baixo de intersecção é justificado pela presença de gabaritos com uma grande margem de segurança tendo apenas uma pequena parte central correspondendo a um nódulo. A figura 33 mostra uma marcação do banco de imagens DDSM feita com uma grande margem de segurança.




Figura 34 – Imagem original (a) e gabarito feito por especialista usando uma margem de segurança (b), limites reais da massa (c)

Para o segundo método de aplicação dos templates, como as marcações são em geral pequenos círculos, qualquer intersecção com o gabarito é considerado um acerto na detecção.

4.7 Sumário

Propõe-se, neste trabalho, um sistema CADDx completo para detecção de massas em imagens mamográficas. O sistema, que contém característica modular, é dividido em etapas e foi construído na forma de *plug-ins* para o software de processamento de imagens ImageJ. A principal ideia do sistema é automatizar o algoritmo de detecção de massas Ozeke usando redes neurais Perceptron multicamadas para determinar automaticamente quais argumentos devem ser usados pelo algoritmo em cada imagem. As redes funcionarão como aproximadores universais mapeando atributos das imagens em saídas, os argumentos a serem utilizados. Para diminuir a complexidade do problema, o método de Ozeke foi modificado e alguns dos seus parâmetros foram eliminados sem, porém, diminuir a eficácia do método. Além disso, o sistema também conta com etapas de pré-processamento, segmentação e extração de atributos de imagens: etapas necessárias à etapa de detecção de massas.

Para treinamento e validação das redes, utilizou-se a estratégia *leave-one-out*, nunca usando uma mesma imagem nas etapas de treinamento e validação de

uma rede neural. Testes empíricos foram feitos para determinar os melhores parâmetros a serem usados no algoritmo de aprendizagem *backpropagation*, a melhor topologia de rede para o problema, qual o melhor conjunto de entrada a ser usado e qual distância usada na extração dos descritores de Haralick obtém melhor resultado quando usados como entrada para as redes neurais.

5. RESULTADOS

Nesse capítulo, são apresentados os resultados referentes à aplicação do algoritmo de remoção de manchas brancas e a segmentação da mama e do músculo peitoral. O restante dos resultados apresentados – seleção de atributos, escolha das topologias e curvas FROC - refere-se à configuração do sistema que usa a equalização de histograma como pré-processamento, já que essa obteve o melhor desempenho quando comparado com as demais. Os resultados referentes aos três pré-processamentos testados podem ser vistos integralmente nos apêndices desse documento.

5.1 Remoção das Bordas das Imagens

Em todas as imagens, as bordas brancas presentes nas beiradas das mamografias foram removidas ou atenuadas sem que parte da mama fosse cortada no processo. A figura 35 mostra exemplos de imagens antes e após o algoritmo de remoção das bordas.




Figura 35 – Exemplos da aplicação do algoritmo para remoção de bordas brancas

5.2 Segmentação da Mama

Em todos os casos a mama foi segmentada de forma correta. A figura 36 mostra exemplos de segmentações obtidas pela aplicação do método de Marques.




Figura 36 – Exemplos de segmentações da mama

5.3 Segmentação do Músculo Peitoral

Os resultados do método para segmentação do músculo peitoral usado foram calculados usando 40 imagens de testes, também do DDSM, e utiliza um sistema de notas visto no artigo de Saltanat *et al* (SALTANAT e HOSSAIN e ALAM, 2010). As notas foram dadas pela especialista Luciana Buffa Verçosa, uma mastologista que trabalha diariamente diagnosticando imagens mamográficas. A tabela 1 mostra o sistema de notas usado e a figura 37 o percentual das notas obtidas nas segmentações. Esses mesmos resultados foram apresentados no artigo de Barbosa Filho (BARBOSA FILHO *et al*, 2011).

Tabela 1 – Sistema de notas utilizado

Nota	Descrição
Exata	A linha segmentada delimita a margem peitoral de forma exata. Qualquer desvio a partir da margem é imperceptível ou insignificante.
Muito Bom	A linha segmentada delimita a margem peitoral exatamente por pelo menos metade do seu comprimento e de forma adequada para a outra metade.
Adequada	A linha segmentada delimita a margem peitoral de forma inexata, mas com precisão suficiente para o fim pretendido.
Insuficiente	A linha segmentada delimita a margem peitoral inadequada por pelo menos metade do seu comprimento.
Inadequada	A linha segmentada está ausente ou é insuficiente para a localização da margem peitoral para o fim pretendido.

Percentual das Notas




Figura 37 – Porcentagem das notas referentes às segmentações

A figura 38 mostra exemplos de segmentação exata (a), muito boa (b), adequada (c), insuficiente (d) e inadequada (e).




Figura 38 – Exemplos de segmentação para cada nota obtida: exata (a), muito boa (b), adequada (c), insuficiente (d), inadequada (e)

5.4 Seleção de Atributos

Como dito anteriormente, todas as permutações dos grupos de atributos disponíveis foram testadas. Nos testes envolvendo os descritores de Haralick, também foi verificado qual distância, no cálculo dos descritores, acarreta um menor erro no treinamento das redes.

As figuras 39 a 42 mostram, em forma de gráfico, a média dos erros obtidos nos testes envolvendo diferentes distâncias no cálculo dos descritores de Haralick para cada conjunto de atributos. É possível perceber que o mesmo padrão se repete nas três primeiras curvas embora o quarto gráfico apresente um comportamento diferente. O uso dos momentos invariantes de Hu em conjunto com os descritores de Haralick fez com que o comportamento da curva, que mede o erro para diferentes distâncias usadas no cálculo dos descritores, fosse diferente das curvas das demais combinações de atributos.




Figura 39 – Escolha da distância usada no cálculo dos descritores de Haralick usando apenas os descritores como entrada para a primeira rede neural: distância $d = 30$ apresentou menor erro que as demais

Na escolha da melhor distância a ser usada no cálculo dos descritores de Haralick, quando apenas esse conjunto de atributos é usado como entrada para a primeira rede neural, a distância $d = 30$ apresentou o menor erro em comparação com outras distâncias se mostrando-se como um mínimo global da curva.




Figura 40 - Escolha da distância usada no cálculo dos descritores de Haralick usando momentos centrais e descritores de Haralick como entrada para a primeira rede: comportamento semelhante ao teste anterior com a distância escolhida também $d = 30$

O mesmo comportamento foi observado na escolha da melhor distância quando os descritores de Haralick são usados como entrada para a primeira rede neural em conjunto com os momentos centrais. É possível observar, inclusive, a presença do mínimo local no mesmo ponto que o teste anterior, a saber, $d = 30$.




Figura 41 - Escolha da distância usada no cálculo dos descritores de Haralick usando momentos centrais, momentos invariantes de Hu além dos descritores como entrada para a primeira rede neural: mínimo local próximo aos testes anteriores no ponto $d = 10$

Na escolha da melhor distância a ser usada no cálculo dos descritores quando todos os grupos de atributos são usados como entrada para a primeira rede neural, apesar de o comportamento ser parecido como o comportamento dos testes anteriores, a distância que apresentou o melhor resultado foi $d = 10$.




Figura 42 - Escolha da distância usada no cálculo dos descritores de Haralick usando momentos invariantes de HU além dos descritores como entrada para a primeira rede neural: comportamento distinto dos demais testes com mínimo local em $d = 130$

Usando apenas os descritores de Haralick em conjunto com os momentos invariantes de Hu observou-se um comportamento diferente dos testes anteriores sem a presença do mínimo local ao redor das primeiras distâncias testadas. Nesse caso, a distância que apresentou menor erro foi $d = 130$.

Após decidir quais distâncias serão usadas no cálculo dos descritores de Haralick para cada conjunto de atributos, é necessário avaliar o erro médio para os conjuntos restantes. Do mesmo modo, 10 redes neurais com diferentes números de neurônios são treinadas e o erro médio é calculado para os conjuntos de atributos que não englobam os descritores. A figura 43 mostra o erro médio no treinamento da primeira rede neural para todos os conjuntos de atributos testados.




Figura 43 – Erro médio no treinamento da primeira rede neural para diferentes conjuntos de atributos: todos os atributos testados foram escolhidos como entrada para a primeira rede neural com os descritores de Haralick calculados usando distância $d = 10$.

É possível observar que o menor erro foi obtido usando os descritores de Haralick, calculados com distância $d = 10$, momentos centrais e momentos invariantes de Hu como entrada da rede e, portanto, esse é o resultado da seleção de atributos para a primeira rede neural.

5.5 Escolha das Topologias

Uma vez decidido quais atributos serão usados no treinamento da primeira rede neural, que indica qual limiar será usado na etapa de binarização, é necessário escolher a topologia da rede. Também é necessário escolher a topologia para a segunda rede neural, responsável por calcular o raio que será usado na etapa de *templates*. É importante lembrar que dois métodos distintos de aplicar os *templates* foram testados e, portanto, são escolhidas topologias diferentes para cada método, uma vez que os valores usados no treinamento das redes em cada abordagem diferem.

A figura 44 mostra o erro médio no treinamento da primeira rede neural para diferentes topologias. É possível observar que as topologias de uma camada

escondida ou com poucos neurônios na segunda camada apresentam um melhor desempenho em comparação com as demais. A topologia de uma camada escondida com 14 neurônios apresentou o menor erro. A figura 45 representa graficamente a topologia escolhida onde x_1 a x_7 representam os descritores de Haralick, x_8 a x_{12} os momentos centrais e x_{13} a x_{19} os momentos invariantes de Hu de uma imagem.




Figura 44 – Erro médio no treinamento da primeira rede neural com diferentes topologias: a topologia de uma camada escondida de 14 neurônios apresentou melhor resultado




Figura 45 – Representação gráfica da topologia escolhida para a primeira rede neural contendo uma camada escondida com 14 neurônios

A figura 46 mostra o erro médio no treinamento da segunda rede neural usando o primeiro método de aplicação dos *templates* para diferentes topologias. Assim como no teste anterior, múltiplas camadas escondidas e um número alto de neurônios por camada implicam um erro maior. A topologia com uma camada escondida de 18 neurônios foi a que apresentou o menor erro. A figura 47 representa graficamente essa topologia onde x_1 a x_6 representam os atributos extraídos da imagem binarizada.




Figura 46 - Erro médio no treinamento da segunda rede neural com diferentes topologias usando o primeiro método de aplicação dos templates: topologia com uma camada escondida de 18 neurônios foi escolhida




Figura 47 - Representação gráfica da topologia escolhida de uma camada escondida com 18 neurônios da segunda rede neural usando o primeiro método de aplicação de templates

A figura 48 mostra o erro médio no treinamento da segunda rede neural usando o segundo método de aplicação dos *templates* para diferentes topologias. Nesse caso, a topologia escolhida foi de duas camadas escondidas com 16 neurônios na primeira camada e dois neurônios na segunda. A figura 49 representa graficamente a topologia escolhida onde x_1 a x_6 representam os atributos extraídos da imagem binarizada.




Figura 48 - Erro médio no treinamento da segunda rede neural usando diferentes topologias e usando o segundo método de aplicação dos *templates*: a topologia com duas camadas escondidas com 16 neurônios na primeira camada e dois na segunda apresentou menor erro.




Figura 49 - Representação gráfica da topologia escolhida da segunda rede neural usando o segundo método de aplicação de templates: duas camadas escondidas com 16 neurônios na primeira camada e dois neurônios na segunda

5.6 Curvas FROC

Após definir os atributos e topologias usadas, treinam-se novamente as redes neurais usando a estratégia de validação cruzada *leave-one-out* e aplica-se o algoritmo de detecção nas imagens de teste usando os valores obtidos nas redes como parâmetros do método. O processo é repetido para diferentes valores de limiar na etapa de aplicação de *templates*, criando assim as curvas FROC para diferentes configurações do sistema.

A figura 50 mostra a curva FROC quando o primeiro método de aplicação dos *templates* é usado. O comportamento pouco usual da curva é justificado pela fusão das marcações nas configurações mais sensíveis do sistema e, consequentemente, diminuição no número de falsos positivos ao custo de uma segmentação excessiva. Maiores comentários sobre esse comportamento são feitas na seção 6.3 desse trabalho. O ponto de operação mais sensível possui 71% de sensibilidade e 4,73 falsos positivos por imagem.




Figura 50 - Curva FROC ao usar a primeira abordagem de aplicação dos templates

A figura 51 mostra a curva FROC obtida quando o segundo método de aplicação dos *templates* é usado. Observa-se um número alto de falsos positivos por imagem embora o comportamento da curva seja mais de acordo com o esperado. O ponto de operação mais sensível da curva atingiu 82% de sensibilidade a um custo de 7,51 falsos positivos por imagem.




Figura 51 - Curva FROC ao usar a segunda abordagem de aplicação dos templates

Como teste adicional, foi calculada outra curva FROC usando esse mesmo método de aplicação dos *templates*, mas apenas considerando as cinco maiores marcações da imagem. A motivação por trás desse experimento é que regiões mais parecidas com o *template* geram marcações maiores, salvo em casos de fusão de marcações. O resultado, exibido na figura 52, mostra uma leve diminuição na sensibilidade, porém uma grande diminuição no número de falsos positivos. O ponto de operação mais sensível atingiu 74% de sensibilidade a um custo de 3,56 falsos positivos por imagem.




Figura 52 - Curva FROC ao usar a segunda abordagem de aplicação dos templates e considerando apenas as cinco maiores marcações de cada imagem

5.7 Protótipo

Para que testes pudessem ser realizados por pessoas que não os autores do trabalho, foi desenvolvido um protótipo com uma interface gráfica simples e objetiva que permite a aplicação do algoritmo de detecção de massas em imagens do tipo TIFF de 12 e 16 bits. O software também permite o armazenamento da imagem com as marcações desenhadas além das regiões de interesse definidas por essas marcações. A figura 53 mostra uma captura de tela do protótipo desenvolvido. No lado direito da interface, a imagem com as marcações feitas pelo sistema é exibida. Na parte central, são exibidas as regiões de interesse recortadas a partir das marcações feitas. Na parte direita da interface ficam os botões referentes ao armazenamento da imagem e das ROIs recortadas.



Figura 53 – Captura de tela do protótipo desenvolvido.

6. DISCUSSÕES

Nesse capítulo serão feitos alguns comentários e discussões a respeito dos diversos resultados obtidos: a segmentação da mama e músculo peitoral, a seleção de atributos, a escolha das topologias e, por fim, a detecção das massas e curvas FROC geradas.

6.1 Segmentação da Mama e do Músculo Peitoral

A etapa de segmentação mostrou bons resultados com 100% de segmentações corretas do contorno da mama e 90% de segmentações do músculo peitoral corretas. Como o objetivo final do trabalho é a construção de um sistema CAD para a detecção de massas, poucos experimentos foram feitos na etapa de segmentação do músculo peitoral. O uso de algoritmos de aumento de contraste, como os testados na etapa de pré-processamento, podem melhorar o desempenho do método proposto. Uma detecção adequada do músculo peitoral em todas as imagens deve ser alcançada já que a extração de atributos da imagem, etapa importantíssima para as etapas posteriores, depende dessa segmentação.

6.2 Seleção de Atributos

A hipótese de que diferentes distâncias, usadas no cálculo dos descritores de Haralick, seriam mais eficientes para diferentes conjuntos de atributos não foi comprovada. Os resultados referentes à seleção da melhor distância no cálculo dos descritores para um mesmo algoritmo de aumento de contraste mostram um comportamento bastante semelhante em todas as combinações de atributos testadas.

Por outro lado, o algoritmo usado na etapa de pré-processamento parece ter influência na distância que melhor apresenta resultados no cálculo dos descritores de Haralick. A figura 54 mostra os gráficos referentes ao erro no treinamento das redes neurais usando os descritores calculados com diferentes distâncias para cada algoritmo de pré-processamento. É possível observar que o comportamento do erro

para diferentes distâncias é diferente para cada algoritmo de pré-processamento usado.




Figura 54 – Curvas referentes ao erro no treinamento da primeira rede neural usando descritores de Haralick calculados com diferentes distâncias quando usado o algoritmo de expansão de histograma (a), aumento de contraste logarítmico (b) e equalização de histograma (c) como pré-processamento

De forma semelhante, os atributos também parecem ter influências diferentes no treinamento das redes neurais de acordo com o pré-processamento usado. Esse comportamento já era esperado uma vez que o histograma da imagem, que é usado direta ou indiretamente no cálculo dos atributos, muda drasticamente de acordo com o algoritmo de pré-processamento utilizado. A figura 55 mostra os erros obtidos no treinamento da primeira rede neural para diferentes atributos usados como entrada para cada algoritmo de pré-processamento testado.




Figura 55 - Erro no treinamento da primeira rede neural usando diferentes atributos como entrada quando usado o algoritmo de expansão de histograma (a), aumento de contraste logarítmico (b) e equalização de histograma (c) como pré-processamento

6.3 Escolha das Topologias

Os resultados da escolha das topologias mostram um aumento no erro advindo das redes neurais quando um número excessivo de neurônios é usado, número que varia de acordo com a rede treinada. Isso é condizente com o fenômeno chamado de *overfitting*, quando a rede neural, ao invés de generalizar o problema desejado, acaba memorizando excessivamente as entradas levando a saídas indesejadas quando um conjunto de teste que não participou do treinamento é posto a prova.

O número de neurônios testados contempla o método de Fletcher-Gloss e a heurística usada na plataforma Weka, duas formas bastante comuns na literatura para determinar o número de neurônios em uma rede neural com uma camada escondida em função do número de entradas da rede (SILVA e SPATTI e FLAUZINO, 2010). Além disso, também se verificaram topologias com mais de uma

camada escondida, indo além do que as heurísticas citadas anteriormente contemplam.

6.3 Desempenho Dos Métodos de Aplicação dos Templates

O primeiro método de aplicação dos *templates* não apresentou um bom desempenho. Assim como no método de Ozekes, as marcações feitas por meio desse método são maiores que aquelas feitas pelo segundo método testado. Por conta disso, nas configurações do sistema em que o número de falsos positivos por imagem é alto, as marcações tendem a se mesclarem provocando um decréscimo no número de falsos positivos ao custo de uma segmentação excessiva na imagem e de marcações de baixa qualidade. Por isso o comportamento pouco usual da curva FROC quando utilizado o primeiro método de aplicação dos *templates*. A figura 56 mostra o método aplicado a uma mesma imagem mamográfica para os diferentes limiares testados.



Figura 56 – Detecção aplicada à uma imagem mamográfica usando o primeiro método de aplicação de templates para diferentes limiares

O segundo método de aplicação de *templates* testado apresentou melhores resultados. Diferentemente do primeiro método, as marcações feitas nas imagens são pequenas e mais difíceis de fundirem, mesmo com um número excessivo de marcações em uma imagem. A figura 57 mostra o método aplicado a mesma imagem mamográfica da figura 56 para diferentes limiares.



Figura 57 - Detecção aplicada à uma imagem mamográfica usando o segundo método de aplicação de templates para diferentes limiares

É importante observar que pequenos erros na segmentação do músculo peitoral podem ocasionar erros na detecção de massas, como mostra a imagem anterior. Algumas segmentações, consideradas adequadas pela especialista, traçam a linha que divide a mama e o músculo peitoral um pouco aquém do ideal fazendo com que uma fina linha do músculo ainda seja visível após a segmentação. Embora isso esteja dentro da margem de segurança proposta pela especialista - é mais seguro ter um pouco de músculo na mama do que cortar parte da imagem contendo tecido mamário – isso, em geral, provoca a segmentação desse resquício de músculo na imagem ocasionando erros na detecção. Na figura 57, mostrada anteriormente, pode-se observar essa segmentação do resquício de músculo peitoral.

6.4 Desempenho do Sistema

O sistema apresentou desempenho diferente para cada algoritmo de pré-processamento testado, com a equalização de histograma dando os melhores resultados. A figura 58 mostra as curvas FROC geradas considerando apenas as cinco maiores marcações feitas em cada imagem.




Figura 58 – Curvas froc do sistema para diferentes algoritmos de pré-processamento

É interessante perceber que uma simples heurística, a desconsideração de outras marcações que não as cinco maiores, conseguiu diminuir significativamente o número de falsos positivos por imagem sem diminuir, na mesma proporção, a sensibilidade do sistema. O uso de métodos mais complexos, como a classificação das ROIs extraídas das marcações feitas, pode diminuir o número de falsos positivos sem tanto impacto na sensibilidade do sistema.

6.5 Comparação Com Outros Trabalhos

A tabela 2 faz uma comparação entre o método proposto, o método original de Ozekes, o ImageChecker[®] e o algoritmo Roi Hunter (CASCIO *et al*, 2006). Foram escolhidas as taxas de sensibilidade e FPI das configurações de maior sensibilidade apresentadas nas publicações de cada trabalho. A tabela 3 mostra, semelhante à tabela anterior, informações relativas aos bancos de imagens usados nos testes de cada um desses três métodos.

Tabela 2 – Comparação entre diferentes sistemas de detecção de massas e o método proposto sem (1) e com (2) a heurística de redução de falsos positivos

	Sensibilidade	FPI	Automático	Classificação de ROI para Redução de FPI
Ozekes	93%	1,3	Não	Não
ImageChecker[®]	90%	1,4	Sim	Sim
Método Proposto¹	82%	7,51	Sim	Não
Roi Hunter	82%	2,8	Sim	Sim
Método Proposto²	74%	3,56	Sim	Não

Tabela 3 – Comparação dos bancos de imagens usados nos testes de diferentes sistemas de detecção de massas

	Número de Imagens	Banco de Imagens	Dados Estatísticos das Imagens
Ozekes	52	Mini-MIAS	11 casos normais, 41 casos de câncer onde 22 são massas circunscritas e 19 massas espiculadas. Nenhuma informação sobre densidade das mamas.
ImageChecker[®]	767	Desconhecido	Desconhecidos.
Método Proposto	120	DDSM	120 casos de câncer de diferentes tipos. Número igual de imagens para cada um dos quatro tipos de densidade mamária segundo o BI-RADS [®] .
Roi Hunter	3762	MAGIC-5	57% das imagens tem densidade glandular, 37% são fibroadiposas e 6% são imagens densas. Também é informada a idade das pacientes: 63% tem entre 50 a 69 anos, 26% de 40 a 50 anos e 11% de 25 a 40 anos.

As comparações feitas na tabela 2 são insuficientes se as informações referentes aos bancos de imagens usados por cada um dos métodos comparados são deixadas de lado. A primeira vista, o método proposto perde para os métodos de Ozekes e para o CAD ImageChecker[®] em questão de sensibilidade e se iguala ao Roi Hunter. Em contrapartida, esse último possui uma taxa de falsos positivos por imagem menor. Uma possível justifica para esse desempenho pode ser encontrada na tabela 2, ao se comparar os bancos de imagens usados na medição da performance de cada trabalho.

O desempenho do método de Ozekes citado na tabela deve ser usado para mostrar o potencial do algoritmo na detecção de massas já que, por não ser um método automático, seu uso em sistemas CAD é improvável.

O ImageChecker® não apresenta em sua documentação oficial, ou em sua *homepage*, informações relativas ao banco de imagens usado tais como a idade das pacientes e estatísticas sobre as densidades mamárias. Além disso, uma classificação de ROI é feita pelo sistema para eliminar possíveis falsos positivos em suas detecções: *“The algorithm ranks its findings by prominence of features, places marks on those regions above a fixed threshold (operating point) and then sends the results to the review workstation”* (IMAGECHECKER, 2011). Tal estratégia de eliminação de falsos positivos não é utilizada no presente trabalho, deixando o método proposto em certa desvantagem.

Em relação ao algoritmo Roi Hunter, o sistema apresentou a mesma sensibilidade com um número maior de falsos positivos por imagem. Esse algoritmo também prevê uma classificação de ROI por meio de redes neurais. Sem essa classificação, a sensibilidade do algoritmo aumenta para 93% ao custo do aumento excessivo na taxa de falsos positivos chegando a, aproximadamente, 7,5 FPI (CASCIO *et al*, 2006). Além disso, o banco de imagens usado nos testes não apresenta uma distribuição igual entre as classes de densidade das imagens. Enquanto a validação do método proposto foi feita usando o mesmo número de imagens para cada classe de densidade do BI-RADS® (ACR, 2003), o trabalho de CASCIO *et al* utiliza um banco onde apenas 6% das imagens são consideradas densas (equivalentes à classificação BI-RADS® 4) e 57% apresentam densidade glandular (equivalentes à classificação BI-RADS® 2 e 3). Além disso, 63% das imagens correspondem a exames feitos por mulheres com idade entre 50 e 69 anos que, normalmente, possuem mamas pouco densas. Em comparação a esse banco de imagens, o banco usado na validação do método proposto pode ser considerado mais rígido, já que imagens de mamas densas são mais difíceis de processar do que imagens de mamas com baixa densidade, o que ocasionaria uma queda na sensibilidade do sistema.

Por fim, o uso de um limiar para limitar o número máximo de marcações feitas por imagem mostrou que a taxa de falsos positivos pode ser reduzida a níveis aceitáveis, próximos aos dos algoritmos que usam métodos mais complexos de

redução da taxa de falsos positivos. A sensibilidade do sistema reduziu para 74% com a aplicação dessa heurística.

7. CONSIDERAÇÕES FINAIS

O objetivo de construir um sistema CAD completo e automático para detecção de massas foi atingido. O método proposto é uma combinação de filtros e processamentos simples, tais como a segmentação por binarização e a aplicação de *templates*, embora a forma como foram usados e a integração de cada módulo não sejam triviais. Fato similar também ocorre na sua arquitetura. Cada etapa – pré-processamento, segmentação e detecção das massas – foi codificada como um *plugin* para o ImageJ, permitindo que módulos sejam usados individualmente em outros trabalhos envolvendo sistemas CADDx para mamografia, embora, uma vez integrados, resultem em um sistema completo para detecção de massas.

A automação do sistema também deve ser ressaltada: nenhuma intervenção humana é requisitada. Os parâmetros da etapa de binarização e aplicação dos *templates* são obtidos por meio da execução de redes neurais artificiais previamente treinadas e salvas em disco. Essas redes tiveram suas topologias e atributos de entrada selecionados por intermédio de exaustivos testes empíricos.

Por fim, ainda que as taxas de sensibilidade e FPI não tenham superado as taxas de sensibilidade do ImageChecker®, o método proposto apresentou resultados promissores chegando a 82% de sensibilidade usando a mesma quantidade de imagens para as quatro densidades mamárias, segundo o BI-RADS®, incluindo as densidades da categoria 3 (heterogeneamente densas) e da categoria 4 (extremamente densas).

A aplicação de uma simples heurística na redução do número de falsos positivos por imagem resultou em um valor próximo àqueles obtidos nos outros trabalhos usados como comparação. Isso, aliada à taxa de sensibilidade resultante de 74%, mostra que métodos mais complexos de redução de FPI podem ajudar a diminuir a taxa de falsos positivos do sistema sem tanto impacto em sua sensibilidade.

Trabalhos futuros devem se concentrar, principalmente, em três tópicos: melhoramento da segmentação do músculo peitoral, uso de algoritmos de pré-processamento locais e classificação das ROIs encontradas. A melhora na segmentação do músculo peitoral diminuirá a ocorrência de grandes marcações

feitas nas faixas estreitas de músculo peitoral consideradas como parte da mama por causa de uma má segmentação. O uso de pré-processamentos locais, isto é, que usam o conceito de vizinhança em seus cálculos, pode ajudar na detecção de massas envoltas em tecido denso como aquelas encontradas em mamas de alta densidade. Por último, a classificação das ROIs encontradas deve ser usada como método de diminuição de falsos positivos, preferencialmente substituindo a heurística usada de delimitação no número de marcações feitas por imagem.

REFERÊNCIAS BIBLIOGRÁFICAS

ACR (2003) *ACR BI-RADS® - Breast Imaging and Reporting Data System*. 4ª Edição. Reston: American College of Radiology.

BARBOSA FILHO, J. R. B. *et al* (2011) *Segmentação do Músculo Peitoral em Imagens Mamográficas Através do Recorte Automático de ROI e da Binarização de Otsu*. In: VII Workshop de Visão Computacional. Anais do Evento, Curitiba, p. 198.

BILSKA-WOLAK, A. O. *et al* (2005) *Computer Aid for Decision to Biopsy Breast Masses on Mammography: Validation on New Cases*. Academic Radiology, v. 12, n. 6, p. 671.

BLANKS, R. G. *et al*. (2000) *Effect of NHS breast screening programme on mortality from breast cancer in England and Wales, 1990-8: comparison of observed with predicted mortality*. British Medical Journal, v. 321, p. 665.

BOSE, J. S. C.; KARNAN, M.; SIVAKUMAR, R. (2010) *Detection of Masses in Digital Mammograms*. International Journal of Computer and Network Security, v. 2, n. 2, p. 78.

BOYER, B. *et al*. (2009) *CAD in questions/answers: Review of literature*. European Journal of Radiology, v. 69, n. 1, p. 24.

BOYLE, P.; LEVIN, B. (2008) *World Cancer Report*. International Agency for Research on Cancer, Lyon, França, p. 412.

CASCIO, D. *et al* (2006) *Mammogram Segmentation by Contour Searching and Massive Lesion Classification with Neural Network*. IEEE Transactions on Nuclear Science, v. 53, n. 5, p. 2827.

COPPIN, B. (2004) *Artificial Intelligence Illuminated*. 1ª Edição. Estados Unidos: Jones and Bartlett Publishers.

DOI, K. (2007) *Computer-aided diagnosis in medical imaging: Historical review, current status and future potential*. Computer Medical Imaging and Graphics, v. 31, p. 198.

DOI, K. et al. (2005) *Current status and future potential of computer-aided diagnosis in medical imaging*. British Journal of Radiology, n. 78, p. 3-19.

ENCOG (2012) *Encog Java and DotNet Neural Network Framework*. Disponível em < <http://www.heatonresearch.com/encog> >. Acessado em 4/02/2012.

EVANS, A. L. (1981) *The Evaluation of Medical Images*. 1ª Edição. Reino Unido: Taylor & Francis.

FERRARI, R. J. et al (2000) *Segmentação de Mamogramas: Identificação da borda da mama, músculo peitoral e disco glandular*. In: XVII Congresso Brasileiro de Engenharia Biomédica. Anais do Evento, p. 1255.

FERRARI, R. J. et al (2004) *Automatic Identification of the Pectoral Muscle in Mammograms*. IEEE Transactions on Medical Imaging, v. 23, n. 2, p.232.

FERREIRA, T.; RASBAND, W. (2011) *ImageJ User Guide*. Disponível em <<http://imagej.nih.gov/ij/docs/user-guide.pdf>>. Acessado em 2/08/2011.

GAO, X. et al (2010) *On Combining Morphological Component Analysis and Concentric Morphology Model for Mammographic Mass Detection*. IEEE Transactions On Information Technology In Biomedicine, v. 14, n. 2.

GONZALEZ, R. C.; WOODS, R. E. (2002) *Digital Image Processing*. 2ª Edição. New Jersey: Prentice Hall.

HARALICK, M. R.; SHANMUGAM, K.; DINSTEN, I. (1973) *Textural Features for Image Classification*. IEEE Transactions On System, Man And Cybernetics, v. 3, n. 6, p. 610.

HEATH, M. *et al* (2001) *The Digital Database for Screening Mammography*. Proceedings of The Fifth International Workshop on Digital Mammography, p. 212-218.

HENRIQUE, F. (2012) *Aproximação de Funções Matemáticas Utilizando Retropropagação do Erro*. Disponível em <<http://henrique-fabio.blogspot.com/2011/06/aproximacao-de-funcoes-matematicas.html>>. Acessado em 4/02/2012.

HOLOGIC (2011) *R2 ImageChecker® Digital CAD*. Disponível em: <<http://www.hologic.com/pt/breast-screening/imagechecker/>>. Acessado em 20/07/2011.

HU, M-K. (1962) Visual Pattern Recognition by Moment Invariants. IRE Transactions on Information Theory, v. 8, n. 2, p. 179-187.

IMAGECHECKER (2009) *Field-proven CAD Technology*. Disponível em: <http://www.hologic.com/data/DS-00025_03-09_ImageChecker_9.3.pdf>. Acessado em: 21/07/2011.

IMAGECHECKER (2011) *R2 ImageChecker® CAD Algorithm*. Disponível em: <<http://www.hologic.com/pt/breast-screening/imagechecker/algorithm/>>. Acessado em: 20/02/2011.

IMAGEJ (2011) Image Processing and Analysis in Java. Disponível em <<http://rsbweb.nih.gov/ij/index.html>>. Acessado em: 11/08/2011.

INCA; MINISTÉRIO DA SAÚDE (2004) *Controle do Câncer de Mama – Documento de Consenso*. Brasil, p. 7.

INCA; MINISTÉRIO DA SAÚDE (2011) *Estimativas 2012: Incidência de Câncer no Brasil*, Rio de Janeiro, Brasil, p. 34.

KARSSEMEIJER, N. *et al* (1998) Automated classification of parenchymal patterns in mammograms. *Physics in Medicine and Biology*, v. 43, p. 365.

LAPIMO (2011) *Laboratório de Análise e Processamento de Imagens Médicas e Odontológicas*. Disponível em: <<http://lapimo.sel.eesc.usp.br/lapimo/drupal/>>. Acessado em 20/07/2011.

MARQUES, F. L. S. N. (2001) *Investigação em Processamento de Imagens Mamográficas Para Auxílio Ao Diagnóstico De Imagens Densas*. Tese (Doutorado) – Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos.

MASALA, G. L. (2006) *Computer Aided Detection on Mammography*. World Academy of Science, Engineering and Technology. 2006, p. 1.

MCCULLOCH, W. S.; PITTS, W. (1943) *A Logical Calculus Of The Ideas Immanent Nervous Activity*. *Bulletin of Mathematical Biophysics*, v. 5., p. 115.

MERCIMEK, M.; GULEZ, K.; MUMCU, T. V. (2005) Real Object Recognition Using Moment Invariants. *Sadhana*, v. 30, n. 5, p. 765-775.

OTSU, N. (1979) *A Threshold Selection Method from Gray-Level Histograms*. *IEEE Transactions on Systems, Man, And Cybernetics*, v. 9, n. 1, p. 62.

OZEKES, S.; OSMAN, O.; ÇARMURCU, A. Y. (2005) *Mammographic Mass Detection Using a Mass Template*. *Korean Journal of Radiology*, v.6, p. 221.

RIBEIRO, P. B. (2006) *Classificação por Análise de Contornos de Nódulos Mamários Utilizando Redes Neurais Artificiais*. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. (1986) *Parallel Distributed Processing*. Volume 1, capítulo 8. Massachusetts: MIT Press.

SALTANAT, N.; HOSSAIN M. A.; ALAM, M. A. (2010) An Efficient Pixel Value Based Mapping Scheme to Delineate Pectoral Muscle from Mammograms. In.: *Fifth*

International Conference on Bio-Inspired Computing: Theories and Applications. Anais do Evento, China, p. 1510.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. (2010) *Redes Neurais Artificiais: para engenharia e ciência aplicadas*. 1ª Edição. São Paulo: Artliber.

TANGARO, S. et al (2006) *Mass lesion detection in mammographic images using Haralick textural features*. Proceedings of CompIMAGE, Computational Modelling of Object Represented in Images: Fundamentals, Methods and Applications, Coimbra, Portugal.

VAN ENGELAND, S.; KARSSEMEIJER, N. (2007) *Combining two mammographic projections in a computer aided mass detection method*. Medical Physics, v. 34, n. 3, p. 898.

APÊNDICE A – EXPANSÃO DE HISTOGRAMA

A seguir são mostrados os resultados referentes aos testes de seleção de atributos e escolha de topologias das redes neurais quando a expansão de histograma é usada como algoritmo de pré-processamento nas imagens. Primeiro, as distâncias usadas no cálculo dos descritores de Haralick para cada conjunto de atributos é definida. Em seguida, comparam-se os erros médios obtidos com os erros obtidos no treinamento usando os conjuntos que não possuem os descritores de Haralick. O conjunto de atributos que apresentar o menor erro é o escolhido para servir de entrada para a primeira rede neural. Após isso, são feitos diversos testes para escolher as topologias da primeira e segunda rede.

A.1 Escolha da Distância no Cálculo dos Descritores de Haralick

As tabelas 4 a 7 mostram o erro obtido no treinamento de cada topologia testada para diferentes conjuntos de atributos e diferentes distâncias usadas no cálculo dos descritores de Haralick. As células da tabela possuem cores proporcionais a seus valores: células mais verdes representam erros mais baixos enquanto células mais vermelhas comportam erros de um valor maior. As figuras 59 a 62 mostram, em forma de gráfico, o erro médio obtido para cada distância.

Tabela 4 – Erro no treinamento da primeira rede neural com diferentes topologias usando como entrada descritores de Haralick calculado com diferentes distâncias

		Distância																				
		1	10	20	30	40	50	60	70	80	90	100	110	120	130	140	150	160	170	180	190	200
Neurônios	2	0,617	0,605	0,642	0,632	0,635	0,624	0,618	0,621	0,612	0,620	0,609	0,609	0,604	0,608	0,609	0,599	0,619	0,623	0,621	0,629	0,624
	4	0,645	0,653	0,675	0,673	0,654	0,653	0,654	0,644	0,645	0,645	0,647	0,634	0,634	0,626	0,630	0,618	0,636	0,645	0,650	0,654	0,655
	6	0,670	0,693	0,691	0,703	0,681	0,675	0,681	0,670	0,664	0,670	0,665	0,657	0,648	0,654	0,650	0,651	0,655	0,662	0,665	0,671	0,667
	8	0,687	0,707	0,700	0,696	0,688	0,686	0,682	0,683	0,681	0,676	0,676	0,675	0,670	0,665	0,663	0,647	0,674	0,671	0,673	0,680	0,683
	10	0,697	0,706	0,707	0,701	0,704	0,695	0,692	0,691	0,687	0,686	0,682	0,683	0,679	0,672	0,672	0,667	0,671	0,677	0,681	0,688	0,690
	12	0,702	0,709	0,713	0,714	0,708	0,705	0,701	0,695	0,691	0,688	0,688	0,680	0,679	0,672	0,673	0,667	0,678	0,686	0,686	0,691	0,691
	14	0,699	0,715	0,717	0,713	0,711	0,709	0,702	0,700	0,692	0,692	0,691	0,683	0,681	0,675	0,676	0,673	0,684	0,686	0,688	0,690	0,696
	16	0,703	0,718	0,717	0,717	0,713	0,712	0,707	0,704	0,702	0,698	0,692	0,697	0,685	0,688	0,682	0,675	0,692	0,690	0,697	0,696	0,701
	18	0,706	0,716	0,724	0,724	0,713	0,713	0,711	0,707	0,700	0,699	0,696	0,692	0,686	0,687	0,685	0,680	0,685	0,692	0,697	0,697	0,698
	20	0,708	0,718	0,720	0,718	0,717	0,710	0,712	0,707	0,704	0,697	0,694	0,691	0,688	0,684	0,685	0,681	0,692	0,691	0,696	0,698	0,699
Média		0,683	0,694	0,701	0,699	0,692	0,688	0,686	0,682	0,678	0,677	0,674	0,670	0,666	0,663	0,662	0,656	0,669	0,672	0,675	0,679	0,680

Tabela 5 - Erro no treinamento da primeira rede neural com diferentes topologias usando como entrada momentos centrais e descritores de Haralick calculado com diferentes distâncias

		Distância																				
		1	10	20	30	40	50	60	70	80	90	100	110	120	130	140	150	160	170	180	190	200
Neurônios	2	0,660	0,666	0,677	0,684	0,685	0,667	0,670	0,675	0,666	0,660	0,665	0,661	0,672	0,667	0,664	0,671	0,668	0,661	0,674	0,673	0,674
	4	0,683	0,685	0,687	0,687	0,684	0,679	0,686	0,688	0,682	0,684	0,678	0,687	0,671	0,678	0,671	0,673	0,673	0,689	0,683	0,680	0,690
	6	0,698	0,700	0,707	0,703	0,703	0,702	0,696	0,695	0,699	0,696	0,697	0,688	0,690	0,693	0,695	0,691	0,705	0,704	0,698	0,696	0,701
	8	0,714	0,720	0,725	0,720	0,719	0,716	0,718	0,710	0,714	0,713	0,705	0,710	0,707	0,707	0,704	0,709	0,715	0,712	0,717	0,720	0,714
	10	0,714	0,717	0,723	0,721	0,719	0,714	0,716	0,712	0,714	0,714	0,711	0,711	0,713	0,704	0,709	0,707	0,709	0,715	0,720	0,717	0,716
	12	0,723	0,732	0,729	0,732	0,730	0,725	0,724	0,722	0,717	0,723	0,716	0,718	0,719	0,715	0,716	0,712	0,720	0,722	0,722	0,722	0,727
	14	0,726	0,732	0,731	0,729	0,728	0,727	0,726	0,721	0,723	0,724	0,719	0,717	0,718	0,713	0,715	0,717	0,723	0,723	0,727	0,723	0,727
	16	0,727	0,731	0,733	0,732	0,729	0,728	0,729	0,725	0,726	0,724	0,723	0,723	0,721	0,722	0,721	0,719	0,726	0,727	0,726	0,730	0,728
	18	0,729	0,732	0,735	0,735	0,730	0,732	0,730	0,731	0,728	0,729	0,724	0,722	0,723	0,723	0,720	0,720	0,726	0,724	0,730	0,731	0,731
	20	0,730	0,733	0,735	0,734	0,732	0,730	0,732	0,727	0,727	0,725	0,722	0,723	0,722	0,722	0,720	0,720	0,726	0,728	0,726	0,728	0,729
Melhor Caso		0,711	0,715	0,718	0,718	0,716	0,712	0,713	0,711	0,710	0,709	0,706	0,706	0,706	0,704	0,704	0,704	0,709	0,711	0,712	0,712	0,714

Tabela 6 - Erro no treinamento da primeira rede neural com diferentes topologias usando como entrada momentos centrais, momentos invariantes de Hu e descritores de Haralick calculado com diferentes distâncias

		Distância																				
		1	10	20	30	40	50	60	70	80	90	100	110	120	130	140	150	160	170	180	190	200
Neurônios	2	0,490	0,493	0,491	0,491	0,492	0,492	0,492	0,490	0,492	0,490	0,492	0,488	0,491	0,490	0,493	0,489	0,490	0,493	0,494	0,495	0,494
	4	0,498	0,496	0,498	0,497	0,503	0,500	0,499	0,500	0,498	0,504	0,500	0,495	0,496	0,496	0,497	0,497	0,501	0,502	0,500	0,502	0,499
	6	0,525	0,527	0,531	0,525	0,527	0,527	0,526	0,526	0,525	0,527	0,524	0,522	0,520	0,525	0,522	0,521	0,526	0,526	0,525	0,533	0,532
	8	0,569	0,576	0,578	0,575	0,569	0,572	0,574	0,570	0,569	0,569	0,568	0,568	0,565	0,563	0,565	0,563	0,569	0,573	0,570	0,574	0,580
	10	0,560	0,575	0,576	0,573	0,571	0,573	0,573	0,569	0,568	0,565	0,562	0,562	0,554	0,558	0,554	0,554	0,559	0,565	0,567	0,565	0,568
	12	0,600	0,611	0,612	0,608	0,605	0,601	0,603	0,598	0,598	0,593	0,594	0,588	0,588	0,587	0,586	0,583	0,590	0,593	0,597	0,598	0,600
	14	0,583	0,595	0,594	0,591	0,589	0,584	0,582	0,580	0,581	0,579	0,578	0,574	0,573	0,570	0,567	0,570	0,575	0,578	0,580	0,580	0,583
	16	0,578	0,588	0,593	0,590	0,587	0,584	0,580	0,583	0,578	0,582	0,576	0,573	0,572	0,572	0,571	0,569	0,577	0,577	0,580	0,581	0,582
	18	0,596	0,607	0,608	0,606	0,604	0,600	0,598	0,597	0,593	0,591	0,588	0,585	0,586	0,585	0,583	0,582	0,585	0,590	0,591	0,592	0,596
	20	0,589	0,601	0,600	0,600	0,595	0,597	0,592	0,591	0,591	0,589	0,588	0,587	0,585	0,583	0,581	0,579	0,587	0,590	0,592	0,593	0,594
Melhor Caso		0,559	0,567	0,568	0,566	0,564	0,563	0,562	0,560	0,559	0,559	0,557	0,554	0,553	0,553	0,552	0,551	0,556	0,559	0,560	0,561	0,563

Tabela 7 - Erro no treinamento da primeira rede neural com diferentes topologias usando como entrada momentos invariantes de Hu e descritores de Haralick calculado com diferentes distâncias

		Distância																				
		1	10	20	30	40	50	60	70	80	90	100	110	120	130	140	150	160	170	180	190	200
Neurônios	2	0,478	0,478	0,480	0,479	0,477	0,477	0,479	0,478	0,478	0,477	0,478	0,477	0,479	0,476	0,477	0,477	0,477	0,478	0,478	0,478	0,479
	4	0,481	0,481	0,480	0,479	0,482	0,480	0,481	0,478	0,482	0,481	0,479	0,478	0,480	0,480	0,477	0,478	0,481	0,482	0,480	0,482	0,483
	6	0,486	0,493	0,493	0,491	0,491	0,491	0,489	0,486	0,488	0,489	0,487	0,485	0,485	0,486	0,484	0,483	0,487	0,485	0,488	0,488	0,490
	8	0,502	0,515	0,512	0,510	0,507	0,508	0,506	0,501	0,504	0,501	0,498	0,494	0,495	0,496	0,493	0,491	0,497	0,500	0,499	0,500	0,503
	10	0,500	0,510	0,514	0,509	0,508	0,507	0,505	0,503	0,503	0,501	0,496	0,496	0,496	0,494	0,491	0,490	0,496	0,498	0,499	0,500	0,503
	12	0,512	0,529	0,529	0,524	0,520	0,517	0,515	0,514	0,512	0,510	0,506	0,505	0,500	0,501	0,498	0,496	0,502	0,507	0,507	0,508	0,509
	14	0,510	0,523	0,522	0,520	0,518	0,515	0,513	0,510	0,510	0,507	0,505	0,504	0,501	0,500	0,497	0,497	0,502	0,504	0,506	0,507	0,509
	16	0,511	0,525	0,525	0,522	0,519	0,517	0,514	0,513	0,511	0,510	0,507	0,505	0,503	0,500	0,499	0,496	0,503	0,506	0,506	0,510	0,509
	18	0,516	0,533	0,532	0,528	0,524	0,521	0,519	0,519	0,515	0,514	0,509	0,508	0,506	0,502	0,500	0,499	0,506	0,509	0,511	0,511	0,512
	20	0,517	0,532	0,534	0,529	0,526	0,522	0,520	0,518	0,516	0,514	0,511	0,508	0,506	0,503	0,501	0,499	0,508	0,508	0,510	0,511	0,513
Média		0,501	0,512	0,512	0,509	0,507	0,505	0,504	0,502	0,502	0,500	0,498	0,496	0,495	0,494	0,492	0,490	0,496	0,498	0,498	0,499	0,501




Figura 59 - Escolha da distância usada no cálculo dos descritores de Haralick usando apenas os descritores como entrada para a primeira rede neural




Figura 60 - Escolha da distância usada no cálculo dos descritores de Haralick usando momentos centrais e descritores como entrada para a primeira rede neural




Figura 61- Escolha da distância usada no cálculo dos descritores de Haralick usando momentos centrais, momentos invariantes de Hu e descritores como entrada para a primeira rede neural




Figura 62 - Escolha da distância usada no cálculo dos descritores de Haralick usando momentos invariantes de Hu e descritores como entrada para a primeira rede neural

A.2 Escolha dos Atributos

A tabela 8 mostra o erro obtido no treinamento da primeira rede neural com diferentes topologias para os conjuntos de atributos que não possuem os descritores de Haralick.

Tabela 8 - Erro no treinamento da primeira rede neural com diferentes topologias usando como entrada momentos centrais, momentos centrais e momentos invariantes de Hu e apenas momentos invariantes de Hu

		Momentos Centrais	Momentos Centrais e Momentos Invariantes de Hu	Momentos Invariantes de Hu
Neurônios	2	0,717	0,489	0,464
	4	0,737	0,492	0,456
	6	0,746	0,504	0,443
	8	0,746	0,520	0,433
	10	0,755	0,522	0,425
	12	0,756	0,536	0,420
	14	0,756	0,535	0,416
	16	0,761	0,539	0,403
	18	0,760	0,542	0,400
	20	0,762	0,542	0,402
Média		0,750	0,522	0,426

A figura 63 compara os erros médios obtidos anteriormente para cada conjunto de atributos testado. Observa-se que o conjunto contendo apenas os momentos invariantes de Hu apresentou menor erro em relação aos demais.




Figura 63 - Erro médio no treinamento da primeira rede neural para diferentes conjuntos de atributos

A.3 Escolha das Topologias

A tabela 9 mostra os erros obtidos no treinamento da primeira rede neural para diferentes topologias usando o conjunto de atributos escolhidos na etapa anterior – momentos invariantes de Hu.

Tabela 9 – Erro obtido no treinamento da primeira rede neural para diferentes topologias usando momentos invariantes de Hu como entrada

		Camadas					
		1	2	3	2*	2*	2*
Neurônios	10	0,418	0,458	0,484	0,471	0,317	0,211
	20	0,400	0,229	0,500	0,451	0,239	0,224
	30	0,363	0,214	0,462	0,442	0,230	0,226
	40	0,320	0,230	0,415	0,452	0,229	0,222
	50	0,290	0,225	0,363	0,449	0,227	0,231
	60	0,246	0,225	0,280	0,444	0,225	0,228
	70	0,225	0,226	0,305	0,419	0,227	0,231
	80	0,201	0,228	0,271	0,428	0,224	0,239
	90	0,187	0,227	0,275	0,431	0,227	0,224
	100	0,179	0,222	0,261	0,429	0,225	0,235
	110	0,168	0,222	0,289	0,433	0,224	0,236
	120	0,167	0,208	0,316	0,400	0,228	0,229
	130	0,174	0,205	0,257	0,415	0,230	0,235
	140	0,169	0,212	0,235	0,404	0,229	0,236
	150	0,177	0,230	0,242	0,422	0,231	0,217
Média		0,246	0,237	0,330	0,433	0,234	0,228

A figura 64 mostra os erros médios da tabela anterior em formato de gráfico. A topologia de uma camada escondida com 120 neurônios apresentou o menor erro entre as topologias testadas.




Figura 64 - Erro médio no treinamento da primeira rede neural com diferentes topologias

A tabela 10 mostra os erros obtidos no treinamento da segunda rede neural, usando o primeiro método de aplicação de templates, para diferentes topologias.

Tabela 10 - Erro obtido no treinamento da segunda rede neural usando o primeiro método de aplicação de templates e diferentes topologias

		Camadas					
		1	2	3	2*	2*	2*
Neurônios	2	0,166	0,160	0,160	0,162	0,161	0,160
	4	0,166	0,161	0,162	0,162	0,160	0,162
	6	0,167	0,165	0,162	0,162	0,162	0,168
	8	0,163	0,161	0,166	0,163	0,162	0,161
	10	0,164	0,172	0,172	0,164	0,163	0,165
	12	0,161	0,188	0,191	0,163	0,162	0,166
	14	0,164	0,201	0,184	0,165	0,164	0,173
	16	0,164	0,232	0,203	0,161	0,157	0,171
	18	0,161	0,263	0,188	0,162	0,159	0,171
	20	0,164	0,336	0,195	0,163	0,165	0,182
Média		0,164	0,204	0,178	0,163	0,162	0,168

A figura 65 mostra os erros médios da tabela anterior em formato de gráfico. A topologia de duas camadas escondidas com 16 e quatro neurônios, respectivamente, apresentou o menor erro entre as topologias testadas.




Figura 65 - Erro médio no treinamento da segunda rede neural usando o primeiro método de aplicação de templates e diferentes topologias

A tabela 11 mostra os erros obtidos no treinamento da segunda rede neural, usando o segundo método de aplicação de templates, para diferentes topologias.

Tabela 11 - Erro obtido no treinamento da segunda rede neural usando o segundo método de aplicação de templates e diferentes topologias

		Camadas					
		1	2	3	2*	2*	2*
Neurônios	2	0,184	0,178	0,180	0,178	0,178	0,178
	4	0,182	0,183	0,178	0,183	0,178	0,183
	6	0,186	0,181	0,182	0,180	0,181	0,188
	8	0,183	0,187	0,186	0,180	0,179	0,178
	10	0,189	0,205	0,199	0,182	0,186	0,195
	12	0,187	0,229	0,198	0,182	0,182	0,185
	14	0,182	0,227	0,213	0,185	0,188	0,198
	16	0,184	0,302	0,226	0,182	0,182	0,178
	18	0,186	0,369	0,218	0,182	0,197	0,195
	20	0,188	0,407	0,223	0,181	0,183	0,216
Média		0,185	0,247	0,200	0,181	0,183	0,189

A figura 66 mostra os erros médios da tabela anterior em formato de gráfico. A topologia de duas camadas escondidas com dois neurônios cada apresentou o menor erro entre as topologias testadas.




Figura 66 - Erro médio no treinamento da segunda rede neural usando o primeiro método de aplicação de templates e diferentes topologias

A.4 Curvas FROC

A figura 67 mostra a curva FROC quando o primeiro método de aplicação dos templates é usado. O comportamento pouco usual da curva é justificado pela fusão das marcações nas configurações mais sensíveis do sistema e, conseqüentemente, diminuição no número de falsos positivos – porém ao custo de uma segmentação excessiva. O ponto de operação mais sensível possui 73% de sensibilidade e 2,17 falsos positivos por imagem.




Figura 67 - Curva FROC ao usar a primeira abordagem de aplicação dos templates

A figura 68 mostra a curva FROC obtida quando o segundo método de aplicação dos templates é usado. Observa-se um número alto de falsos positivos por imagem nesse resultado embora o comportamento da curva seja muito mais de acordo com o esperado. O ponto de operação mais sensível da curva atingiu 78% de sensibilidade a um custo de 7,7 falsos positivos por imagem.




Figura 68 - Curva FROC ao usar a segunda abordagem de aplicação dos templates

Como teste adicional, foi calculada outra curva FROC usando esse mesmo método de aplicação dos templates, mas apenas considerando as cinco maiores marcações da imagem. O resultado, exibido na figura 69, mostra uma leve diminuição na sensibilidade atingida, porém uma grande diminuição no número de falsos positivos. O ponto de operação mais sensível atingiu 68% de sensibilidade a um custo de 3,45 falsos positivos por imagem.




Figura 69 - Curva FROC ao usar a segunda abordagem de aplicação dos templates e considerando apenas as cinco maiores marcações de cada imagem

APÊNDICE B – EQUALIZAÇÃO DE HISTOGRAMA

A seguir são mostrados os resultados referentes aos testes de seleção de atributos e escolha de topologias das redes neurais quando a equalização de histograma é usada como algoritmo de pré-processamento nas imagens. Primeiro, as distâncias usadas no cálculo dos descritores de Haralick para cada conjunto de atributos é definida. Em seguida, comparam-se os erros médios obtidos com os erros obtidos no treinamento usando os conjuntos que não possuem os descritores de Haralick. O conjunto de atributos que apresentar o menor erro é o escolhido para servir de entrada para a primeira rede neural. Após isso, são feitos diversos testes para escolher as topologias da primeira e segunda rede.

B.1 Escolha da Distância no Cálculo dos Descritores de Haralick

As tabelas 12 a 15 mostram o erro obtido no treinamento de cada topologia testada para diferentes conjuntos de atributos e diferentes distâncias usadas no cálculo dos descritores de Haralick. As células da tabela possuem cores proporcionais a seus valores: células mais verdes representam erros mais baixos enquanto células mais vermelhas comportam erros de um valor maior. As figuras 70 a 73 mostram, em forma de gráfico, o erro médio obtido para cada distância.

Tabela 12 – Erro no treinamento da primeira rede neural com diferentes topologias usando como entrada descritores de Haralick calculado com diferentes distâncias

		Distância																				
		1	10	20	30	40	50	60	70	80	90	100	110	120	130	140	150	160	170	180	190	200
Neurônios	2	0,228	0,218	0,222	0,218	0,225	0,220	0,220	0,222	0,219	0,219	0,220	0,222	0,221	0,226	0,226	0,225	0,225	0,226	0,226	0,226	0,227
	4	0,226	0,226	0,219	0,221	0,226	0,224	0,225	0,225	0,219	0,223	0,225	0,225	0,226	0,226	0,225	0,226	0,226	0,225	0,226	0,226	0,224
	6	0,225	0,225	0,223	0,220	0,224	0,223	0,222	0,224	0,224	0,224	0,223	0,220	0,225	0,225	0,228	0,225	0,225	0,226	0,225	0,226	0,223
	8	0,230	0,223	0,225	0,219	0,228	0,226	0,227	0,223	0,225	0,225	0,226	0,225	0,224	0,224	0,226	0,225	0,226	0,224	0,227	0,227	0,233
	10	0,229	0,229	0,224	0,224	0,226	0,227	0,225	0,230	0,228	0,227	0,226	0,226	0,225	0,227	0,227	0,226	0,227	0,227	0,227	0,230	0,235
	12	0,230	0,230	0,229	0,226	0,233	0,230	0,232	0,234	0,229	0,230	0,230	0,231	0,234	0,232	0,231	0,235	0,233	0,233	0,232	0,237	0,241
	14	0,236	0,233	0,230	0,228	0,235	0,232	0,237	0,235	0,232	0,238	0,238	0,238	0,235	0,240	0,234	0,236	0,245	0,246	0,244	0,244	0,244
	16	0,243	0,236	0,232	0,227	0,243	0,239	0,243	0,241	0,241	0,247	0,243	0,243	0,248	0,249	0,249	0,244	0,254	0,247	0,245	0,253	0,241
	18	0,251	0,238	0,232	0,231	0,259	0,247	0,250	0,253	0,248	0,253	0,255	0,255	0,254	0,258	0,255	0,256	0,251	0,252	0,241	0,241	0,241
	20	0,266	0,238	0,234	0,228	0,270	0,272	0,261	0,268	0,268	0,271	0,267	0,264	0,269	0,264	0,263	0,265	0,261	0,276	0,249	0,244	0,246
Melhor Caso		0,236	0,230	0,227	0,224	0,237	0,234	0,234	0,236	0,233	0,236	0,235	0,235	0,236	0,237	0,236	0,236	0,237	0,238	0,234	0,235	0,236

Tabela 13 - Erro no treinamento da primeira rede neural com diferentes topologias usando como entrada momentos centrais e descritores de Haralick calculado com diferentes distâncias

		Distância																				
		1	10	20	30	40	50	60	70	80	90	100	110	120	130	140	150	160	170	180	190	200
Neurônios	2	0,236	0,237	0,226	0,226	0,237	0,230	0,233	0,235	0,233	0,237	0,236	0,237	0,230	0,240	0,237	0,236	0,238	0,236	0,238	0,237	0,227
	4	0,241	0,231	0,224	0,224	0,240	0,236	0,236	0,235	0,230	0,237	0,236	0,237	0,237	0,237	0,237	0,237	0,237	0,237	0,238	0,240	0,230
	6	0,236	0,233	0,227	0,228	0,237	0,237	0,236	0,236	0,237	0,235	0,238	0,237	0,239	0,238	0,238	0,238	0,239	0,239	0,239	0,238	0,232
	8	0,236	0,226	0,229	0,225	0,236	0,235	0,236	0,236	0,237	0,236	0,236	0,237	0,237	0,238	0,237	0,238	0,239	0,236	0,240	0,237	0,230
	10	0,230	0,230	0,225	0,227	0,231	0,231	0,230	0,233	0,234	0,232	0,233	0,232	0,233	0,236	0,235	0,232	0,232	0,229	0,230	0,233	0,225
	12	0,231	0,233	0,230	0,226	0,232	0,235	0,233	0,231	0,232	0,236	0,233	0,232	0,236	0,232	0,235	0,233	0,234	0,240	0,233	0,232	0,232
	14	0,236	0,240	0,235	0,227	0,235	0,238	0,237	0,232	0,234	0,234	0,236	0,241	0,239	0,235	0,230	0,232	0,240	0,237	0,237	0,236	0,234
	16	0,231	0,238	0,230	0,229	0,238	0,234	0,228	0,231	0,232	0,231	0,225	0,230	0,226	0,225	0,230	0,237	0,225	0,230	0,239	0,236	0,231
	18	0,237	0,235	0,237	0,223	0,230	0,231	0,233	0,229	0,229	0,232	0,226	0,227	0,227	0,232	0,230	0,235	0,238	0,236	0,235	0,231	0,238
	20	0,249	0,247	0,244	0,241	0,248	0,254	0,254	0,243	0,248	0,250	0,250	0,253	0,253	0,250	0,254	0,252	0,257	0,262	0,260	0,256	0,255
Melhor Caso		0,236	0,235	0,231	0,228	0,237	0,236	0,235	0,234	0,235	0,236	0,235	0,236	0,236	0,236	0,236	0,237	0,238	0,238	0,239	0,238	0,233

Tabela 14 - Erro no treinamento da primeira rede neural com diferentes topologias usando como entrada momentos centrais, momentos invariantes de Hu e descritores de Haralick calculado com diferentes distâncias

		Distância																				
		1	10	20	30	40	50	60	70	80	90	100	110	120	130	140	150	160	170	180	190	200
Neurônios	2	0,219	0,219	0,219	0,219	0,224	0,219	0,221	0,219	0,220	0,219	0,221	0,219	0,219	0,221	0,219	0,222	0,219	0,222	0,223	0,223	0,219
	4	0,220	0,220	0,219	0,219	0,220	0,221	0,223	0,221	0,223	0,223	0,219	0,219	0,220	0,219	0,219	0,221	0,219	0,222	0,222	0,221	0,220
	6	0,221	0,219	0,219	0,219	0,223	0,219	0,219	0,222	0,220	0,219	0,219	0,219	0,219	0,219	0,220	0,221	0,220	0,219	0,225	0,220	0,219
	8	0,221	0,219	0,219	0,219	0,220	0,221	0,222	0,220	0,218	0,219	0,219	0,219	0,220	0,220	0,218	0,218	0,217	0,221	0,218	0,219	0,219
	10	0,219	0,220	0,219	0,219	0,219	0,221	0,219	0,218	0,218	0,219	0,219	0,219	0,219	0,218	0,218	0,219	0,218	0,220	0,220	0,220	0,219
	12	0,219	0,218	0,219	0,219	0,218	0,219	0,218	0,221	0,218	0,218	0,219	0,219	0,219	0,219	0,218	0,219	0,217	0,217	0,219	0,218	0,218
	14	0,218	0,216	0,216	0,217	0,221	0,220	0,216	0,217	0,214	0,216	0,215	0,218	0,217	0,217	0,220	0,215	0,221	0,215	0,218	0,220	0,216
	16	0,217	0,214	0,216	0,215	0,216	0,216	0,218	0,212	0,218	0,217	0,213	0,216	0,215	0,215	0,217	0,215	0,218	0,216	0,217	0,219	0,215
	18	0,220	0,215	0,215	0,216	0,220	0,219	0,219	0,218	0,216	0,217	0,218	0,216	0,218	0,219	0,217	0,218	0,219	0,219	0,220	0,221	0,215
	20	0,224	0,219	0,222	0,221	0,225	0,224	0,222	0,224	0,224	0,224	0,224	0,225	0,225	0,223	0,222	0,225	0,223	0,223	0,225	0,224	0,224
Melhor Caso		0,220	0,218	0,218	0,218	0,221	0,220	0,220	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,220	0,221	0,220	0,218

Tabela 15 - Erro no treinamento da primeira rede neural com diferentes topologias usando como entrada momentos invariantes de Hu e descritores de Haralick calculado com diferentes distâncias

		Distância																				
		1	10	20	30	40	50	60	70	80	90	100	110	120	130	140	150	160	170	180	190	200
Neurônios	2	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219
	4	0,219	0,219	0,219	0,219	0,219	0,219	0,220	0,222	0,222	0,219	0,219	0,219	0,219	0,219	0,220	0,219	0,224	0,219	0,219	0,219	0,220
	6	0,220	0,219	0,219	0,224	0,220	0,219	0,220	0,219	0,219	0,219	0,224	0,219	0,219	0,219	0,220	0,219	0,219	0,219	0,219	0,219	0,219
	8	0,219	0,219	0,219	0,219	0,219	0,218	0,219	0,219	0,219	0,219	0,219	0,219	0,220	0,219	0,219	0,219	0,219	0,219	0,219	0,220	0,220
	10	0,219	0,219	0,219	0,220	0,219	0,219	0,219	0,220	0,219	0,220	0,219	0,219	0,219	0,219	0,220	0,219	0,219	0,220	0,220	0,219	0,224
	12	0,219	0,219	0,220	0,219	0,221	0,220	0,219	0,220	0,220	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,219	0,220	0,220	0,220	0,224
	14	0,218	0,219	0,220	0,220	0,219	0,218	0,219	0,219	0,218	0,219	0,218	0,218	0,219	0,217	0,220	0,220	0,221	0,220	0,222	0,220	0,228
	16	0,217	0,220	0,221	0,221	0,219	0,221	0,217	0,217	0,218	0,218	0,219	0,219	0,219	0,218	0,220	0,219	0,225	0,220	0,219	0,221	0,228
	18	0,217	0,219	0,221	0,223	0,221	0,225	0,221	0,220	0,218	0,220	0,219	0,222	0,225	0,219	0,222	0,219	0,219	0,219	0,226	0,219	0,228
	20	0,226	0,224	0,220	0,225	0,220	0,223	0,223	0,222	0,222	0,224	0,221	0,222	0,222	0,222	0,221	0,221	0,219	0,226	0,221	0,221	0,226
Melhor Caso		0,219	0,220	0,220	0,221	0,220	0,220	0,220	0,220	0,219	0,220	0,220	0,219	0,220	0,219	0,220	0,220	0,220	0,220	0,220	0,220	0,224




Figura 70 - Escolha da distância usada no cálculo dos descritores de Haralick usando apenas os descritores como entrada para a primeira rede neural




Figura 71 - Escolha da distância usada no cálculo dos descritores de Haralick usando momentos centrais e descritores como entrada para a primeira rede neural




Figura 72- Escolha da distância usada no cálculo dos descritores de Haralick usando momentos centrais, momentos invariantes de Hu e descritores como entrada para a primeira rede neural




Figura 73 - Escolha da distância usada no cálculo dos descritores de Haralick usando momentos invariantes de Hu e descritores como entrada para a primeira rede neural

B.2 Escolha dos Atributos

A tabela 16 mostra o erro obtido no treinamento da primeira rede neural com diferentes topologias para os conjuntos de atributos que não possuem os descritores de Haralick.

Tabela 16 - Erro no treinamento da primeira rede neural com diferentes topologias usando como entrada momentos centrais, momentos centrais e momentos invariantes de Hu e apenas momentos invariantes de Hu

		Momentos Centrais	Momentos Centrais e Momentos Invariantes de Hu	Momentos Invariantes de Hu
Neurônios	2	0,427	0,231	0,225
	4	0,454	0,231	0,227
	6	0,469	0,231	0,226
	8	0,498	0,230	0,227
	10	0,545	0,229	0,228
	12	0,568	0,229	0,230
	14	0,594	0,226	0,228
	16	0,620	0,224	0,229
	18	0,631	0,226	0,227
	20	0,623	0,230	0,225
Média		0,543	0,229	0,227

A figura 74 compara os erros médios obtidos anteriormente para cada conjunto de atributos testado. Observa-se que o conjunto contendo os três grupos de atributos - momentos centrais, momentos invariantes de Hu e descritores de Haralick - apresentou o menor erro em relação aos demais.




Figura 74 - Erro médio no treinamento da primeira rede neural para diferentes conjuntos de atributos

B.3 Escolha das Topologias

A tabela 17 mostra os erros obtidos no treinamento da primeira rede neural para diferentes topologias usando o conjunto de atributos escolhidos na etapa anterior – momentos centrais, momentos invariantes de Hu e descritores de Haralick.

Tabela 17 – Erro obtido no treinamento da primeira rede neural para diferentes topologias usando momentos invariantes de Hu como entrada

		Camadas					
		1	2	3	4	5	6
Neurônios	2	0,219	0,219	0,229	0,219	0,219	0,219
	4	0,220	0,219	0,225	0,219	0,219	0,219
	6	0,220	0,219	0,226	0,220	0,219	0,220
	8	0,220	0,219	0,220	0,219	0,219	0,219
	10	0,225	0,219	0,221	0,219	0,225	0,219
	12	0,218	0,225	0,224	0,219	0,219	0,225
	14	0,216	0,219	0,228	0,219	0,222	0,219
	16	0,218	0,227	0,242	0,219	0,220	0,219
	18	0,219	0,218	0,266	0,219	0,220	0,225
	20	0,225	0,226	0,287	0,225	0,225	0,225
	22	0,225	0,261	0,310	0,219	0,219	0,219
	24	0,224	0,305	0,277	0,219	0,225	0,220
	26	0,225	0,350	0,306	0,219	0,226	0,225
	28	0,219	0,354	0,287	0,219	0,227	0,225
	30	0,222	0,350	0,304	0,219	0,225	0,220
Média		0,221	0,255	0,257	0,220	0,222	0,221

A figura 75 mostra os erros médios da tabela anterior em formato de gráfico. A topologia de uma camada escondida com 14 neurônios apresentou o menor erro entre as topologias testadas.




Figura 75 - Erro médio no treinamento da primeira rede neural com diferentes topologias

A tabela 18 mostra os erros obtidos no treinamento da segunda rede neural, usando o primeiro método de aplicação de templates, para diferentes topologias.

Tabela 18 - Erro obtido no treinamento da segunda rede neural usando o primeiro método de aplicação de templates e diferentes topologias

		Camadas					
		1	2	3	2*	2*	2*
Neurônios	2	0,183	0,176	0,176	0,176	0,176	0,176
	4	0,177	0,177	0,176	0,178	0,177	0,177
	6	0,171	0,175	0,177	0,176	0,176	0,176
	8	0,171	0,177	0,179	0,176	0,179	0,181
	10	0,174	0,196	0,188	0,179	0,178	0,190
	12	0,170	0,196	0,189	0,178	0,176	0,180
	14	0,172	0,224	0,204	0,175	0,179	0,200
	16	0,170	0,292	0,200	0,179	0,177	0,187
	18	0,167	0,290	0,205	0,176	0,174	0,194
	20	0,169	0,320	0,223	0,177	0,178	0,188
	22	0,171	0,420	0,225	0,179	0,179	0,199
	24	0,170	0,494	0,191	0,177	0,184	0,202
	26	0,172	0,531	0,208	0,177	0,176	0,194
	28	0,170	0,543	0,203	0,175	0,175	0,201
	30	0,170	0,556	0,213	0,174	0,179	0,211
Média		0,172	0,318	0,197	0,177	0,178	0,190

A figura 76 mostra os erros médios da tabela anterior em formato de gráfico. A topologia de uma camada escondida com 18 neurônios apresentou o menor erro entre as topologias testadas.




Figura 76 - Erro médio no treinamento da segunda rede neural usando o primeiro método de aplicação de templates e diferentes topologias

A tabela 19 mostra os erros obtidos no treinamento da segunda rede neural, usando o segundo método de aplicação de templates, para diferentes topologias.

Tabela 19 - Erro obtido no treinamento da segunda rede neural usando o segundo método de aplicação de templates e diferentes topologias

		Camadas					
		1	2	3	4	5	6
Neurônios	2	0,231	0,227	0,229	0,224	0,225	0,227
	4	0,229	0,227	0,224	0,228	0,224	0,229
	6	0,226	0,227	0,231	0,227	0,230	0,228
	8	0,225	0,228	0,241	0,230	0,231	0,220
	10	0,223	0,248	0,236	0,232	0,227	0,230
	12	0,226	0,245	0,259	0,228	0,228	0,230
	14	0,222	0,263	0,245	0,227	0,231	0,233
	16	0,224	0,317	0,245	0,220	0,230	0,241
	18	0,224	0,375	0,264	0,229	0,224	0,249
	20	0,220	0,435	0,273	0,223	0,233	0,240
Média		0,225	0,279	0,245	0,227	0,228	0,233

A figura 77 mostra os erros médios da tabela anterior em formato de gráfico. A topologia de duas camadas escondidas com oito neurônios em cada camada apresentou o menor erro entre as topologias testadas.




Figura 77- Erro médio no treinamento da segunda rede neural usando o primeiro método de aplicação de templates e diferentes topologias

B.4 Curvas FROC

A figura 78 mostra a curva FROC, quando o primeiro método de aplicação dos templates é usado. O comportamento pouco usual da curva é justificado pela fusão das marcações nas configurações mais sensíveis do sistema e, consequentemente, diminuição no número de falsos positivos – porém ao custo de uma segmentação excessiva. O ponto de operação mais sensível possui 71% de sensibilidade e 4,73 falsos positivos por imagem.




Figura 78 - Curva FROC ao usar a primeira abordagem de aplicação dos templates

A figura 79 mostra a curva FROC obtida, quando o segundo método de aplicação dos templates é usado. Observa-se um número alto de falsos positivos por imagem nesse resultado embora o comportamento da curva seja muito mais de acordo com o esperado. O ponto de operação mais sensível da curva atingiu 82% de sensibilidade a um custo de 7,51 falsos positivos por imagem.




Figura 79 - Curva FROC ao usar a segunda abordagem de aplicação dos templates

Como teste adicional, foi calculada outra curva FROC usando esse mesmo método de aplicação dos templates, mas apenas considerando as cinco maiores marcações da imagem. O resultado, exibido na figura 80, mostra uma leve diminuição na sensibilidade atingida, porém uma grande diminuição no número de falsos positivos. O ponto de operação mais sensível atingiu 74% de sensibilidade a um custo de 3,56 falsos positivos por imagem.




Figura 80 - Curva FROC ao usar a segunda abordagem de aplicação dos templates e considerando apenas as cinco maiores marcações de cada imagem

APÊNDICE C – AUMENTO DE CONTRASTE LOGARÍTMICO

A seguir, são mostrados os resultados referentes aos testes de seleção de atributos e escolha de topologias das redes neurais quando o aumento de contraste logarítmico, seguido da expansão de histograma, é usado como algoritmo de pré-processamento nas imagens. Primeiro, as distâncias usadas no cálculo dos descritores de Haralick para cada conjunto de atributos é definida. Em seguida, comparam-se os erros médios obtidos com os erros obtidos no treinamento usando os conjuntos que não possuem os descritores de Haralick. O conjunto de atributos que apresentar o menor erro é o escolhido para servir de entrada para a primeira rede neural. Após isso, são feitos diversos testes para escolher as topologias da primeira e segunda rede.

C.1 Escolha da Distância no Cálculo dos Descritores de Haralick

As tabelas 20 a 23 mostram o erro obtido no treinamento de cada topologia testada para diferentes conjuntos de atributos e diferentes distâncias usadas no cálculo dos descritores de Haralick. As células da tabela possuem cores proporcionais a seus valores: células mais verdes representam erros mais baixos enquanto células mais vermelhas comportam erros de um valor maior. As figuras 81 a 84 mostram, em forma de gráfico, o erro médio obtido para cada distância.

Tabela 20 – Erro no treinamento da primeira rede neural com diferentes topologias usando como entrada descritores de Haralick calculado com diferentes distâncias

		Distância																				
		1	10	20	30	40	50	60	70	80	90	100	110	120	130	140	150	160	170	180	190	200
Neurônios	2	0,469	0,458	0,424	0,423	0,394	0,399	0,387	0,395	0,396	0,411	0,415	0,383	0,360	0,374	0,380	0,372	0,362	0,367	0,366	0,366	0,373
	4	0,527	0,512	0,474	0,475	0,436	0,424	0,428	0,417	0,442	0,441	0,440	0,409	0,403	0,398	0,413	0,403	0,389	0,386	0,405	0,408	0,417
	6	0,553	0,549	0,518	0,502	0,449	0,444	0,444	0,435	0,448	0,447	0,459	0,431	0,420	0,419	0,432	0,409	0,412	0,419	0,409	0,424	0,418
	8	0,553	0,541	0,521	0,515	0,458	0,466	0,461	0,464	0,454	0,465	0,464	0,450	0,449	0,439	0,432	0,439	0,432	0,426	0,442	0,421	0,435
	10	0,568	0,570	0,543	0,518	0,475	0,465	0,473	0,480	0,470	0,480	0,483	0,466	0,456	0,450	0,455	0,445	0,435	0,447	0,430	0,427	0,444
	12	0,597	0,598	0,578	0,561	0,507	0,502	0,497	0,504	0,520	0,510	0,521	0,486	0,492	0,472	0,492	0,478	0,478	0,471	0,469	0,469	0,476
	14	0,614	0,614	0,598	0,587	0,521	0,519	0,527	0,530	0,522	0,535	0,543	0,516	0,519	0,514	0,512	0,510	0,492	0,496	0,498	0,503	0,495
	16	0,637	0,628	0,617	0,604	0,550	0,558	0,553	0,559	0,567	0,569	0,558	0,553	0,546	0,547	0,529	0,531	0,532	0,539	0,540	0,533	0,524
	18	0,654	0,647	0,635	0,624	0,578	0,562	0,574	0,570	0,575	0,596	0,593	0,566	0,559	0,554	0,563	0,538	0,549	0,546	0,547	0,546	0,541
	20	0,674	0,655	0,632	0,627	0,576	0,582	0,571	0,579	0,592	0,594	0,592	0,579	0,575	0,579	0,569	0,574	0,574	0,565	0,555	0,560	0,556
Média		0,585	0,577	0,554	0,544	0,494	0,492	0,492	0,493	0,499	0,505	0,507	0,484	0,478	0,474	0,478	0,470	0,466	0,466	0,466	0,466	0,468

Tabela 21 - Erro no treinamento da primeira rede neural com diferentes topologias usando como entrada momentos centrais e descritores de Haralick calculado com diferentes distâncias

		Distância																				
		1	10	20	30	40	50	60	70	80	90	100	110	120	130	140	150	160	170	180	190	200
Neurônios	2	0,324	0,322	0,312	0,311	0,321	0,311	0,311	0,304	0,310	0,302	0,306	0,310	0,313	0,309	0,310	0,309	0,308	0,311	0,306	0,312	0,303
	4	0,323	0,320	0,309	0,313	0,309	0,315	0,313	0,311	0,307	0,316	0,309	0,315	0,313	0,310	0,310	0,310	0,306	0,306	0,308	0,312	0,308
	6	0,333	0,324	0,327	0,323	0,322	0,320	0,324	0,322	0,318	0,323	0,321	0,320	0,317	0,319	0,315	0,315	0,318	0,316	0,317	0,320	0,313
	8	0,354	0,346	0,339	0,346	0,330	0,335	0,332	0,331	0,331	0,333	0,339	0,324	0,327	0,325	0,325	0,324	0,329	0,325	0,324	0,324	0,322
	10	0,373	0,354	0,347	0,355	0,345	0,345	0,338	0,339	0,345	0,351	0,348	0,338	0,333	0,334	0,337	0,335	0,334	0,328	0,330	0,331	0,332
	12	0,364	0,364	0,363	0,365	0,336	0,345	0,348	0,343	0,344	0,341	0,353	0,345	0,337	0,343	0,332	0,326	0,334	0,334	0,334	0,334	0,332
	14	0,382	0,365	0,363	0,361	0,347	0,340	0,341	0,346	0,346	0,353	0,350	0,338	0,341	0,342	0,342	0,329	0,330	0,338	0,335	0,338	0,340
	16	0,391	0,386	0,370	0,364	0,360	0,348	0,356	0,354	0,353	0,362	0,356	0,353	0,354	0,342	0,349	0,352	0,341	0,342	0,344	0,356	0,350
	18	0,387	0,369	0,374	0,362	0,352	0,345	0,352	0,350	0,356	0,361	0,362	0,352	0,344	0,350	0,348	0,340	0,349	0,353	0,347	0,340	0,338
	20	0,412	0,391	0,391	0,368	0,361	0,370	0,364	0,362	0,369	0,374	0,375	0,365	0,370	0,359	0,359	0,366	0,351	0,354	0,356	0,356	0,350
Média		0,364	0,354	0,350	0,347	0,338	0,337	0,338	0,336	0,338	0,341	0,342	0,336	0,335	0,333	0,333	0,331	0,330	0,331	0,330	0,332	0,329

Tabela 22 - Erro no treinamento da primeira rede neural com diferentes topologias usando como entrada momentos centrais, momentos invariantes de Hu e descritores de Haralick calculado com diferentes distâncias

		Distância																				
		1	10	20	30	40	50	60	70	80	90	100	110	120	130	140	150	160	170	180	190	200
Neurônios	2	0,313	0,323	0,318	0,321	0,303	0,312	0,310	0,309	0,310	0,311	0,314	0,309	0,308	0,312	0,308	0,311	0,310	0,308	0,311	0,313	0,303
	4	0,317	0,313	0,312	0,314	0,310	0,308	0,313	0,315	0,313	0,311	0,315	0,311	0,311	0,307	0,310	0,308	0,304	0,308	0,309	0,313	0,306
	6	0,328	0,330	0,326	0,320	0,321	0,321	0,315	0,319	0,322	0,322	0,323	0,316	0,313	0,319	0,318	0,317	0,312	0,314	0,315	0,315	0,311
	8	0,358	0,341	0,342	0,336	0,333	0,331	0,332	0,329	0,334	0,333	0,335	0,328	0,322	0,324	0,326	0,320	0,331	0,326	0,326	0,321	0,323
	10	0,373	0,363	0,354	0,351	0,337	0,336	0,339	0,345	0,346	0,348	0,342	0,336	0,330	0,331	0,331	0,339	0,341	0,334	0,334	0,332	0,334
	12	0,377	0,366	0,359	0,353	0,339	0,342	0,342	0,355	0,351	0,354	0,345	0,336	0,346	0,337	0,329	0,336	0,326	0,336	0,333	0,335	0,333
	14	0,390	0,373	0,358	0,360	0,344	0,344	0,347	0,352	0,352	0,352	0,351	0,346	0,341	0,343	0,341	0,330	0,338	0,338	0,340	0,334	0,338
	16	0,401	0,371	0,358	0,368	0,352	0,356	0,352	0,354	0,358	0,353	0,360	0,346	0,341	0,352	0,347	0,338	0,340	0,339	0,339	0,341	0,347
	18	0,402	0,373	0,362	0,367	0,354	0,348	0,359	0,360	0,360	0,348	0,356	0,354	0,354	0,349	0,344	0,344	0,351	0,346	0,340	0,336	0,345
	20	0,405	0,383	0,389	0,384	0,368	0,370	0,365	0,371	0,370	0,370	0,371	0,361	0,359	0,369	0,358	0,358	0,356	0,362	0,357	0,348	0,349
Média		0,366	0,354	0,348	0,347	0,336	0,337	0,338	0,341	0,342	0,340	0,341	0,334	0,333	0,334	0,331	0,330	0,331	0,331	0,331	0,329	0,329

Tabela 23 - Erro no treinamento da primeira rede neural com diferentes topologias usando como entrada momentos invariantes de Hu e descritores de Haralick calculado com diferentes distâncias

		Distância																				
		1	10	20	30	40	50	60	70	80	90	100	110	120	130	140	150	160	170	180	190	200
Neurônios	2	0,308	0,308	0,307	0,307	0,305	0,303	0,303	0,307	0,308	0,309	0,312	0,310	0,303	0,307	0,307	0,306	0,307	0,304	0,307	0,307	0,303
	4	0,307	0,308	0,308	0,308	0,305	0,307	0,304	0,305	0,307	0,309	0,308	0,307	0,308	0,306	0,305	0,301	0,306	0,307	0,305	0,306	0,305
	6	0,309	0,308	0,310	0,309	0,309	0,309	0,311	0,311	0,309	0,309	0,312	0,308	0,308	0,308	0,308	0,308	0,308	0,308	0,307	0,303	0,308
	8	0,314	0,314	0,311	0,310	0,312	0,312	0,313	0,312	0,313	0,313	0,312	0,309	0,311	0,309	0,309	0,310	0,309	0,308	0,309	0,310	0,310
	10	0,317	0,316	0,315	0,315	0,313	0,316	0,314	0,314	0,315	0,315	0,315	0,311	0,310	0,311	0,310	0,310	0,311	0,311	0,310	0,313	0,310
	12	0,320	0,318	0,313	0,314	0,314	0,315	0,315	0,315	0,313	0,315	0,315	0,314	0,311	0,314	0,312	0,311	0,311	0,311	0,314	0,310	0,311
	14	0,319	0,311	0,319	0,314	0,314	0,314	0,313	0,313	0,315	0,313	0,314	0,311	0,310	0,312	0,313	0,311	0,310	0,311	0,313	0,309	0,310
	16	0,324	0,327	0,318	0,318	0,317	0,318	0,316	0,320	0,317	0,316	0,316	0,314	0,313	0,318	0,312	0,311	0,311	0,313	0,310	0,314	0,312
	18	0,322	0,311	0,316	0,317	0,317	0,314	0,315	0,315	0,315	0,319	0,317	0,310	0,311	0,314	0,311	0,313	0,311	0,313	0,310	0,308	0,312
	20	0,332	0,325	0,328	0,319	0,317	0,317	0,319	0,318	0,318	0,316	0,318	0,317	0,313	0,312	0,316	0,314	0,313	0,314	0,314	0,313	0,312
Média		0,317	0,315	0,315	0,313	0,312	0,313	0,312	0,313	0,313	0,313	0,314	0,311	0,310	0,311	0,310	0,309	0,310	0,310	0,310	0,309	0,310




Figura 81 - Escolha da distância usada no cálculo dos descritores de Haralick usando apenas os descritores como entrada para a primeira rede neural




Figura 82 - Escolha da distância usada no cálculo dos descritores de Haralick usando momentos centrais e descritores como entrada para a primeira rede neural




Figura 83- Escolha da distância usada no cálculo dos descritores de Haralick usando momentos centrais, momentos invariantes de Hu e descritores como entrada para a primeira rede neural




Figura 84 - Escolha da distância usada no cálculo dos descritores de Haralick usando momentos invariantes de Hu e descritores como entrada para a primeira rede neural

C.2 Escolha dos Atributos

A tabela 24 mostra o erro obtido no treinamento da primeira rede neural com diferentes topologias para os conjuntos de atributos que não possuem os descritores de Haralick.

Tabela 24 - Erro no treinamento da primeira rede neural com diferentes topologias usando como entrada momentos centrais, momentos centrais e momentos invariantes de Hu e apenas momentos invariantes de Hu

		Momentos Centrais	Momentos Centrais e Momentos Invariantes de Hu	Momentos Invariantes de Hu
Neurônios	2	0,315	0,303	0,306
	4	0,318	0,304	0,307
	6	0,325	0,309	0,307
	8	0,330	0,308	0,305
	10	0,348	0,309	0,305
	12	0,368	0,309	0,304
	14	0,385	0,310	0,298
	16	0,402	0,309	0,294
	18	0,420	0,310	0,292
	20	0,425	0,310	0,290
Média		0,364	0,308	0,301

A figura 85 compara os erros médios obtidos anteriormente para cada conjunto de atributos testado. Observa-se que o conjunto contendo apenas os momentos invariantes de Hu apresentou o menor erro em relação aos demais.




Figura 85 - Erro médio no treinamento da primeira rede neural para diferentes conjuntos de atributos

C.3 Escolha das Topologias

A tabela 25 mostra os erros obtidos no treinamento da primeira rede neural para diferentes topologias usando o conjunto de atributos escolhidos na etapa anterior – o conjunto contendo apenas os momentos invariantes de Hu.

Tabela 25 – Erro obtido no treinamento da primeira rede neural para diferentes topologias usando momentos invariantes de Hu como entrada

		Camadas					
		1	2	3	2*	2*	2*
Neurônios	2	0,307	0,307	0,322	0,307	0,305	0,307
	4	0,306	0,307	0,320	0,307	0,306	0,307
	6	0,307	0,306	0,308	0,308	0,307	0,305
	8	0,306	0,300	0,336	0,307	0,305	0,305
	10	0,305	0,279	0,343	0,307	0,305	0,303
	12	0,306	0,291	0,337	0,307	0,306	0,303
	14	0,300	0,262	0,360	0,305	0,291	0,286
	16	0,295	0,249	0,356	0,305	0,303	0,304
	18	0,292	0,215	0,331	0,308	0,296	0,292
	20	0,287	0,256	0,338	0,309	0,297	0,288
	22	0,280	0,256	0,347	0,302	0,301	0,295
	24	0,277	0,259	0,349	0,306	0,307	0,288
	26	0,267	0,259	0,315	0,313	0,302	0,282
	28	0,274	0,263	0,375	0,309	0,301	0,278
	30	0,274	0,266	0,338	0,306	0,306	0,277
Média		0,292	0,272	0,338	0,307	0,303	0,295

A figura 86 mostra os erros médios da tabela anterior em formato de gráfico. A topologia de duas camadas escondidas com 18 neurônios cada apresentou o menor erro entre as topologias testadas.




Figura 86 - Erro médio no treinamento da primeira rede neural com diferentes topologias

A tabela 26 mostra os erros obtidos no treinamento da segunda rede neural, usando o primeiro método de aplicação de templates, para diferentes topologias.

Tabela 26 - Erro obtido no treinamento da segunda rede neural usando o primeiro método de aplicação de templates e diferentes topologias

		Camadas					
		1	2	3	2*	2*	2*
Neurônios	2	0,2135	0,1946	0,1968	0,1950	0,1950	0,1961
	4	0,2215	0,1943	0,1971	0,1974	0,1959	0,2005
	6	0,2177	0,2005	0,1974	0,1983	0,1960	0,2010
	8	0,2179	0,2038	0,2006	0,1988	0,1988	0,2039
	10	0,2183	0,2027	0,2051	0,2006	0,1978	0,1957
	12	0,2170	0,2009	0,2107	0,2011	0,1983	0,2031
	14	0,2172	0,2237	0,2125	0,1980	0,1997	0,2031
	16	0,2149	0,2573	0,2186	0,1989	0,1980	0,2073
	18	0,2171	0,2385	0,2224	0,1985	0,1969	0,2197
	20	0,2162	0,2512	0,2241	0,1982	0,1998	0,1996
	22	0,2185	0,2747	0,2145	0,1962	0,1993	0,1967
	24	0,2191	0,3126	0,2133	0,1953	0,2039	0,2063
	26	0,2185	0,3392	0,2365	0,1979	0,1995	0,2017
	28	0,2187	0,3573	0,2293	0,1980	0,2016	0,2103
	30	0,2185	0,3630	0,2218	0,1978	0,2023	0,2023
Média		0,218	0,254	0,213	0,198	0,199	0,203

A figura 87 mostra os erros médios da tabela anterior em formato de gráfico. A topologia de duas camadas escondidas com quatro neurônios cada apresentou o menor erro entre as topologias testadas.




Figura 87 - Erro médio no treinamento da segunda rede neural usando o primeiro método de aplicação de templates e diferentes topologias

A tabela 27 mostra os erros obtidos no treinamento da segunda rede neural, usando o segundo método de aplicação de templates, para diferentes topologias.

Tabela 27 - Erro obtido no treinamento da segunda rede neural usando o segundo método de aplicação de templates e diferentes topologias

		Camadas					
		1	2	3	2*	2*	2*
Neurônios	2	0,333	0,318	0,318	0,318	0,318	0,318
	4	0,342	0,318	0,318	0,318	0,319	0,319
	6	0,341	0,322	0,320	0,320	0,317	0,325
	8	0,340	0,328	0,322	0,324	0,320	0,320
	10	0,339	0,324	0,327	0,320	0,318	0,328
	12	0,340	0,337	0,330	0,321	0,326	0,327
	14	0,340	0,337	0,338	0,325	0,319	0,330
	16	0,339	0,336	0,341	0,321	0,313	0,325
	18	0,341	0,353	0,337	0,321	0,325	0,343
	20	0,338	0,365	0,353	0,322	0,321	0,325
Média		0,339	0,334	0,330	0,321	0,320	0,326

A figura 88 mostra os erros médios da tabela anterior em formato de gráfico. A topologia de duas camadas escondidas com 16 neurônios na primeira camada e quatro na segunda apresentou o menor erro entre as topologias testadas.




Figura 88 - Erro médio no treinamento da segunda rede neural usando o primeiro método de aplicação de templates e diferentes topologias

C.4 Curvas FROC

A figura 89 mostra a curva FROC quando o primeiro método de aplicação dos templates é usado. O comportamento pouco usual da curva é justificado pela fusão das marcações nas configurações mais sensíveis do sistema e, consequentemente, diminuição no número de falsos positivos – porém ao custo de uma segmentação excessiva. O ponto de operação mais sensível possui 73% de sensibilidade e 2,24 falsos positivos por imagem.




Figura 89 - Curva FROC ao usar a primeira abordagem de aplicação dos templates

A figura 90 mostra a curva FROC obtida quando o segundo método de aplicação dos templates é usado. Observa-se um número alto de falsos positivos por imagem nesse resultado embora o comportamento da curva seja muito mais de acordo com o esperado. O ponto de operação mais sensível da curva atingiu 77% de sensibilidade a um custo de 6,26 falsos positivos por imagem.




Figura 90 - Curva FROC ao usar a segunda abordagem de aplicação dos templates

Como teste adicional, foi calculada outra curva FROC usando esse mesmo método de aplicação dos templates, mas apenas considerando as cinco maiores marcações da imagem. O resultado, exibido na figura 91, mostra uma leve diminuição na sensibilidade atingida, porém uma grande diminuição no número de falsos positivos. O ponto de operação mais sensível atingiu 69% de sensibilidade a um custo de 3,38 falsos positivos por imagem.




Figura 91 - Curva FROC ao usar a segunda abordagem de aplicação dos templates e considerando apenas as cinco maiores marcações de cada imagem