UNIVERSIDADE FEDERAL DA BAHIA

DISSERTAÇÃO DE MESTRADO

Métodos estatísticos para classificação de massas em mamografias

Rafaela Souza Alcântara

Programa de Pós-Graduação em Ciência da Computação

Salvador
14 de dezembro de 2015

MMCC-Msc-2015

RAFAELA SOUZA ALCÂNTARA

MÉTODOS ESTATÍSTICOS PARA CLASSIFICAÇÃO DE MASSAS EM MAMOGRAFIAS

Esta Dissertação de Mestrado foi apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal da Bahia, como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Orientador: Perfilino Eugênio Ferreira Júnior

Salvador
14 de dezembro de 2015

Ficha catalográfica.

Alcântara, Rafaela Souza

Métodos estatísticos para classificação de massas em mamografias/ Rafaela Souza Alcântara– Salvador, 14 de dezembro de 2015.

76p.: il.

Orientador: Perfilino Eugênio Ferreira Júnior.
Dissertação de Mestrado– UNIVERSIDADE FEDERAL DA BAHIA, INSTITUTO DE MATEMÁTICA, 14 de dezembro de 2015.

TOPICOS PARA FICHA CATALOGRAFICA.
I. Ferreira Júnior, Perfilino Eugênio . II. UNIVERSIDADE FEDERAL DA BAHIA. INSTITUTO DE MATEMÁTICA. III Título.

NUMERO CDD

TERMO DE APROVAÇÃO

RAFAELA SOUZA ALCÂNTARA

MÉTODOS ESTATÍSTICOS PARA CLASSIFICAÇÃO DE MASSAS EM MAMOGRAFIAS

Esta Dissertação de Mestrado foi julgada adequada à obtenção do título de Mestre em Ciência da Computação e aprovada em sua forma final pelo Programa de Pós-Graduação em Ciência da Computação da Universidade Federal da Bahia.

Salvador, 15 de dezembro de 2015

Prof. Dr. Perfilino Eugênio Ferreira Júnior
Universidade Federal da Bahia

Prof. Dr. Antônio Lopes Apolinário Júnior
Universidade Federal da Bahia

Prof. Dr. Marcelo Ossamu Honda
Universidade Estadual de Santa Cruz

AGRADECIMENTOS

Agradeço primeiramente aos meus pais, por todos os anos de dedicação e carinho que tiveram comigo, além de todo o suporte para que esse sonho pudesse ser realizado.

Agradeço à minha irmã, por mais uma vez, conseguir conviver comigo durante esse período do mestrado e por toda paciência, companheirismo, auxílio e, principalmente, muito amor nos momentos finais dessa etapa.

As meus amigos, Clícia, Jhennifer, Tamires e Geovane que dividiram bons e divertidos momentos comigo nessa empreitada de morar na capital.

Aos amigos que conquistei em Salvador, pelos ensinamentos e companheirismo.

Aos amigos que fiz durante a graduação, que me acompanharam até aqui: Bruno e Elenildo.

À Ludimilla, por todas as noites em claro me apoiando na escrita da dissertação e dos artigos.

Aos meus amigos de Feira, que mesmo distantes, se fazem presentes em todos os momentos.

À Samille por todo carinho e paciência nos últimos meses do mestrado.

Agradeço ao meu orientador, Perfilino Eugênio pela competência, dedicação e principalmente pelos ensinamentos transmitidos.

Ao Departamento de Ciência da Computação pela oportunidade de lecionar e expandir meus conhecimentos através da prática acadêmica. Em especial ao professor Frederico Durão por toda dedicação e suporte oferecido à mim durante esse período. Além disso, agradeço aos professores Antônio Apolinário e Christina von Flach por todo apoio.

Aos meus alunos de Cálculo Numérico, por todo o carinho e por me fazerem ter a convicção da escolha certa da profissão.

“Uma imagem vale mais que mil palavras”

—CONFUCIO

RESUMO

O câncer de mama é considerado a segunda neoplasia responsável por mais mortes em mulheres no mundo. Para a prevenção e redução desse número, a mamografia de *screening* é o exame mais utilizado para detecção de nódulos em estágios iniciais. A partir desse exame, o radiologista pode analisar as anomalias e a partir disso desenvolver um diagnóstico. Para aumentar a acurácia dos resultados obtidos a partir das imagens de mamografia, estão sendo desenvolvidos softwares de auxílio à diagnóstico *computer-aided diagnosis* capazes de automatizar o processo de análise da imagem e extrair informações relevantes para a classificação dos nódulos presentes nos exames. Esse trabalho apresenta duas novas metodologias para extração de *features* e classificação de massas e não-massas,s a partir da Entropia de Tsallis extraídas através da matriz de co-ocorrência (GLCM) e através da matriz de valores singulares (SVD) da imagem de mamografia, alcançando uma acurácia máxima de 91.3%

Palavras-chave: Mamografia, Classificação, Extração de *Features*, Entropia de Tsallis

ABSTRACT

Breast cancer has been considered the second neoplasia responsible for women's death in the last few years. To prevent and to reduce these statistics, screening mammography has been used as the most important exam to detect nodules on initial stages. From this exam, the radiologist can analyze anomalies and to provide some diagnostic. To improve the results accuracy rate from mammography images, computer-aided diagnosis softwares have been developed with the ability to automate the image analyses processing and to extract relevant information for mass classifications on screening exams. This work presents two new methodologies for feature extraction for mass and non-mass classification, based on Tsallis entropy calculated from gray level co-occurrence matrix (GLCM) and from singular value decomposition (SVD), reaching the best accuracy rate of 91.3%.

Keywords: Mammography, Classification, Feature Extraction, Tsallis Entropy

SUMÁRIO

Capítulo 1—Introdução 1

1.1 Motivação . . . 3
1.2 Objetivo principal . . . 7
1.3 Organização . . . 7

Capítulo 2—Fundamentação Teórica 9

2.1 Anatomia da Mama Feminina . . . 9
2.2 Câncer de Mama . . . 10
2.3 Mamografia . . . 11
2.4 Fundamentos do Processamento de Imagens . . . 13
2.4.1 Aquisição e representação da imagem digital . . . 13
2.4.2 Equalização de Histograma . . . 14
2.4.3 Quantização de imagens . . . 16
2.4.4 Descrição da imagem . . . 17
2.4.4.1 Chain Code . . . 17
2.5 Matriz de co-ocorrência . . . 18
2.5.1 Definição algébrica . . . 18
2.5.2 Aplicações da GLCM . . . 19
2.6 Decomposição em Valores Singulares (SVD) . . . 24
2.6.1 Definição algébrica . . . 24
2.6.2 Aplicações da SVD . . . 25
2.7 Entropia de Tsallis . . . 26
2.7.1 Definição algébrica . . . 26
2.7.2 Aplicações da Entropia de Tsallis . . . 26
2.8 Fundamentos do Reconhecimento de Padrão . . . 27
2.8.1 Extração de características . . . 28
2.8.2 Classificadores . . . 29
2.8.2.1 Support Vector Machine (SVM) . . . 29

Capítulo 3—Metodologia 31

3.1 Ferramentas . . . 31
3.2 Aquisição das Imagens . . . 32
3.2.1 Digital Database Screening Mammography (DDSM) . . . 32
3.2.1.1 Organização da base de dados . . . 33
3.3 Pré-processamento . . . 34

3.3.1 Extração de ROIs . . . 34
3.4 Equalização da base . . . 36
3.5 Extração de *features* das ROIs . . . 36
3.5.1 Matriz de Co-ocorrência das ROIs . . . 36
3.6 Experimentos com a GLCM da imagem . . . 37
3.6.1 Experimento I sob direções fixas . . . 37
3.6.2 Experimento II sob distâncias fixas . . . 37
3.7 Experimentos com a SVD da GLCM da imagem . . . 38
3.7.1 Experimento I sob direções fixas . . . 38
3.7.2 Experimento II sob distâncias fixas . . . 38
3.8 Classificação das features . . . 39
3.9 Metodologia de avaliação . . . 40
3.9.1 Acurácia . . . 41
3.9.2 Sensibilidade . . . 41
3.9.3 Especificidade . . . 41
3.9.4 Valor Preditivo Positivo (VPP) . . . 42
3.9.5 Valor Preditivo Negativo (VPN) . . . 42

Capítulo 4—Resultados 43

4.1 Experimentos com a GLCM da Imagem . . . 43
4.1.1 Experimento I sob direções fixas . . . 43
4.1.1.1 Parâmetro q variando em $[0.1, 0.9]$ . . . 43
4.1.1.2 Parâmetro q variando em $[1.1, 1.9]$ . . . 44
4.1.1.3 Parâmetro q variando em $[1.31, 1.39]$ . . . 45
4.1.1.4 Parâmetro q variando em $[1.41, 1.49]$ . . . 45
4.1.2 Experimento II sob distâncias fixas . . . 46
4.1.2.1 Parâmetro q variando em $[0.1, 0.9]$ . . . 46
4.1.2.2 Parâmetro q variando em $[1.1, 1.9]$ . . . 46
4.1.2.3 Parâmetro q variando em $[1.11, 1.19]$ . . . 47
4.2 Experimentos com a SVD da GLCM . . . 48
4.2.1 Experimento I sob direções fixas . . . 48
4.2.1.1 Parâmetro q variando em $[0.1, 0.9]$ . . . 48
4.2.1.2 Parâmetro q variando em $[1.1, 1.9]$ . . . 49
4.2.1.3 Parâmetro q variando em $[1.81, 1.89]$ . . . 49
4.2.2 Experimento II sob distâncias fixas . . . 50
4.2.2.1 Parâmetro q variando em $[0.1, 0.9]$ . . . 50
4.2.2.2 Parâmetro q variando em $[1.1, 1.9]$ . . . 51
4.2.2.3 Parâmetro q variando em $[1.71, 1.79]$ . . . 51

Capítulo 5—Conclusão 53

Apêndice A—Apêndice A 55

A.1 Fundamentos da Álgebra Linear 55
A.1.1 Rank da matriz 55
A.1.2 Matriz Diagonal 55
A.1.3 Vetores Ortogonais e Ortonormais 55
A.1.4 Matriz Ortogonal 56
A.1.5 Autovetores e Autovalores 56
A.1.6 Matrizes singulares e não-singulares 56

Apêndice B—Apêndice B 57

LISTA DE FIGURAS

1.1 Formas dos massas em uma mamografia 2

2.1 Estrutura da mama feminina na maturidade 10
2.2 Esquema ilustrativo do exame de mamografia 11
2.3 Tipos de visões do exame de mamografia 12
2.4 Fluxograma simplificado das etapas do Processamento Digital de Imagens 13
2.5 Exemplo de um sensor para aquisição de imagem 14
2.6 Processo de equalização da ROI 15
2.7 Processo de transformação de uma imagem real em uma imagem digital 16
2.8 Codificação de 8 direções para o *Chain Code* 17
2.9 Arquivos de texto presentes nos casos da base DDSM 19
2.10 Representação de um descriminante linear ótimo 30

3.1 Fluxograma simplificado da metodologia do trabalho 31
3.2 Exemplo de *chain code* apresentado na DDSM 34
3.3 Fluxograma simplificado da etapa de aquisição das imagens 34
3.4 Processo de extração da ROI da mamografia 35
3.5 Fluxograma simplificado da etapa de equalização 36

LISTA DE TABELAS

1.1 Códigos BI-RADS 3

2.1 Tabela de fórmulas de *features* utilizadas em (NITHYA; SANTHI, 2011a) 20
2.2 Seleção das 4 mellhores *features* para classificação de ultrassons de fígado apresentada em (VIRMANI et al., 2013) 23
2.3 *Features* utilizadas em cada método de extração (**??**) 29

3.1 Tabela de categorias presentes no arquivo ***.ics*** 33
3.2 Tabela de categorias presentes no arquivo ***.overlay*** 33
3.3 Calculo das estatísticas através das *labels* 41

4.1 Resultados da GLCM da imagem para θ fixo no intervalo $[0.1, 0.9]$ 44
4.2 Resultados da GLCM da imagem para θ fixo no intervalo $[1.1, 1.9]$ 45
4.3 Resultados da GLCM da imagem para θ fixo no intervalo $[1.31, 1.39]$ . . 45
4.4 Resultados da GLCM da imagem para θ fixo no intervalo $[1.41, 1.49]$ . . 46
4.5 Resultados da GLCM da imagem para d fixo no intervalo $[0.1, 0.9]$ 46
4.6 Resultados da GLCM da imagem para d fixo no intervalo $[1.1, 1.9]$ 47
4.7 Resultados da GLCM da imagem para d fixo no intervalo $[1.11, 1.19]$ . . 47
4.8 Resultados da SVD a partir GLCM da imagem para θ fixo no intervalo $[0.1, 0.9]$ 48
4.9 Resultados da SVD a partir GLCM da imagem para θ fixo no intervalo $[1.1, 1.9]$ 49
4.10 Resultados da SVD a partir GLCM da imagem para θ fixo no intervalo $[1.81, 1.89]$ 50
4.11 Resultados da SVD a partir GLCM da imagem para d fixo no intervalo $[0.1, 0.9]$ 50
4.12 Resultados da SVD a partir GLCM da imagem para d fixo no intervalo $[1.1, 1.9]$ 51
4.13 Resultados da SVD a partir GLCM da imagem para d fixo no intervalo $[1.71, 1.79]$ 51

B.1 Resultados da GLCM da imagem para θ fixo no intervalo $[0.1, 0.9]$ 58
B.2 Resultados da GLCM da imagem para θ fixo no intervalo $[1.1, 1.9]$ 59
B.3 Resultados da GLCM da imagem para θ fixo no intervalo $[1.31, 1.39]$ . . 60
B.4 Resultados da GLCM da imagem para θ fixo no intervalo $[1.41, 1.49]$ . . 61
B.5 Resultados da GLCM da imagem para d fixo no intervalo $[0.1, 0.9]$ 62
B.6 Resultados da GLCM da imagem para d fixo no intervalo $[1.1, 1.9]$ 63
B.7 Resultados da GLCM da imagem para d fixo no intervalo $[1.11, 1.19]$ . . 64

B.8 Resultados da SVD a partir GLCM da imagem para θ fixo no intervalo $[0.1, 0.9]$ 65
B.9 Resultados da SVD a partir GLCM da imagem para θ fixo no intervalo $[1.1, 1.9]$ 66
B.10 Resultados da SVD a partir GLCM da imagem para θ fixo no intervalo $[1.81, 1.89]$ 67
B.11 Resultados da SVD a partir GLCM da imagem para d fixo no intervalo $[0.1, 0.9]$ 68
B.12 Resultados da SVD a partir GLCM da imagem para d fixo no intervalo $[1.1, 1.9]$ 69
B.13 Resultados da SVD a partir GLCM da imagem para d fixo no intervalo $[1.71, 1.79]$ 70

NOMENCLATURE

ACR American College of Radiology

ACS American Cancer Society

CADe Computer-Aided Detection

CADx Computer-Aided Diagnoses

DDSM Digital Database Mammography Screening

GLCM Gray-Level Co-occurrence Matrix

IARC International Agency for Research Cancer

INCA Instituto Nacional do Câncer

KB-CAD Knowledge-based Computer-Aided Diagnoses

MDFS Maximum Difference Feature Selection

MIAS Mammographic Image Analysis Society

PDF Probability Density Function

ROI Region of Interest

SBS Sequential Backward Search

SFS Sequential Forward Search

SVM Support Vector Machine

WHO World Health Organization

Capítulo 1

Esse capítulo apresenta a contextualização do problema abordado nesse trabalho, descrevendo os principais objetivos e fazendo uma abordagem primária sobre os trabalhos que já foram desenvolvidos nessa área

INTRODUÇÃO

O câncer de mama, atualmente, é considerado o segundo tipo de câncer mais comum no mundo e a neoplasia que mais atinge as mulheres. De acordo com pesquisas da International Agency for Research Cancer (IARC) (International Agency for Research on Cancer, 2012), em 2012 foram estimados 1.67 milhões de novos casos de câncer de mama no mundo, que representa 25% dos casos de todos os tipos de câncer e até 2017, são previstos 6.25 milhões de casos. A partir dessas estatísticas, ainda em 2012, foram registrados 522.000 mortes por conta dessa neoplasia tornando-se uma das principais causas de morte no mundo.

No ano de 2010, foram registrados 12.705 mortes em função dessa neoplasia. Em 2012, esse número aumentou consideravelmente para 13.591. O câncer de mama vendo sendo considerado a principal causa de morte por câncer em mulheres brasileiras desde o ano de 1979 (VIEIRA, 2012). Entre os homens, o número de óbitos ainda é considerado baixo. No mesmo ano de 2012, foram registradas 154 mortes pela neoplasia, de homens. Segundo o Instituto Nacional do Câncer (INCA) (CANCER, 2014), para o ano de 2014, 57.120 novos casos foram previstos no Brasil.

Fatores genéticos, de ambiente e fatores relacionados ao estilo de vida do paciente têm influência direta no desenvolvimento da neoplasia. Alterações genéticas influenciam nos genes que inibem os tumores e por consequência causam alterações fenotípicas que, no final, acabam por desenvolver o aparecimento do câncer de mama (VIEIRA, 2012). Fatores hereditários compõem um grupo de 10% dos casos de câncer de mama no mundo. Alterações nos genes BRCA 1, BRCA 2 e no p53, responsáveis pela supressão de tumores malignos, são as principais causas do câncer de mama hereditário. Os cânceres não hereditários são maioria e estão associados, principalmente ao estilo de vida que a população vem adotando ao longo das últimas décadas.

Em sua maioria, o câncer de mama atinge mulheres com idade entre 50 e 85 anos (VIEIRA, 2012). A principal causa do número elevado de óbitos está associada a falta de diagnóstico precoce. No Brasil, estima-se que 60% dos casos de câncer de mama

são detectados tardiamente (VIEIRA, 2012). Para a detecção da massa, é aconselhável que a paciente faça o exame clínico da mama uma vez por ano (VIEIRA, 2012). Além desse exame, a mamografia é o exame complementar que deve ser feito com a mesma frequência pelas mulheres. O exame produz um raio-x completo da mama através do mamógrafo[1]. Como resultado, aparelho produz uma imagem de alta qualidade para facilitar o trabalho do radiologista na identificação de pequenas lesões, mesmo que estas ainda estejam em fase inicial.

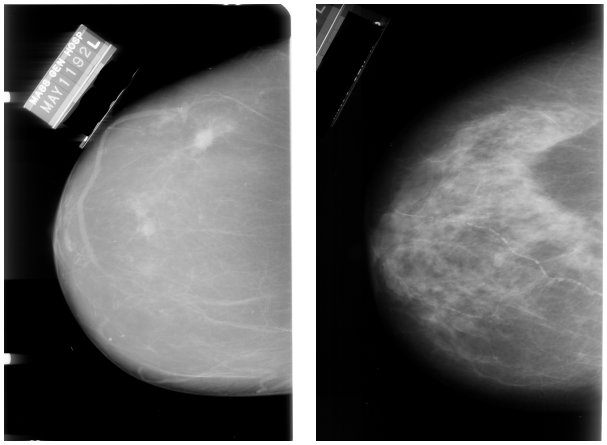

(a) (b)

Figura 1.1 (a) Mamografia com massa maligna (b) Mamografia com calcificações malignas

Os sintomas do câncer de mama estão associados à manchas não dolorosas e de bordas irregulares, edema na pele das mamas e o aumento considerável dos linfonodos[2] axilares (VIEIRA, 2012). Na grande maioria dos casos, essa neoplasia aparece em forma de massas e microcalcificações (JALALIAN et al., 2013), como pode ser visto na Figura 1.1.

As microcalcificações são pequenos depósitos de cálcio no tecido mamário (COX; MORGAN, 2013) e são classificadas de acordo com sua aparência e coloração opaca (JALALIAN et al., 2013) na mamografia.

Em algumas regiões de maior desenvolvimento urbano, e consequentemente, onde as mulheres têm acesso facilitado ao exame de mamografia, o auto-exame foi perdendo sua função, dado que os resultados da mamografia descrevem de maneira mais precisa a situação atual da paciente.

O exame de mamografia, atualmente, é o mais utilizado para detecção de câncer de mama em mulheres. A eficácia desse exame está associada à detecção de massas em sua fase inicial e que ainda são considerados impalpáveis. Entretanto, para mulheres com menos de 40 anos, o exame só é indicado em casos onde existem fatores de riscos associados, como os hereditários. Até essa idade, o tecido da mama ainda possui uma densidade muito alta, o que promove uma dificuldade na identificação das massas no raio-x.

[1] Aparelho utilizado para exames de mamografia

[2] Linfonodos são massas ovais que servem como filtro para os fluídos linfos

Tabela 1.1 Códigos BI-RADS

Categoria	Interpretação	Risco de Câncer	Recomendação
0	Inconclusivo	—	Avaliação adicional
1	Sem achados	0.05%	Rotina de *screening*
2	Achados benignos	0.05%	Rotina de *screening*
3	Achados provavelmente benignos	$\leq 2\%$	Repetir exame em 6 meses (eventual biópsia[3])
4 (A,B,C)	Achados suspeitos de malignidade	$> 20\%$	Biópsia
5	Achados altamente sugestivos de malignidade	$> 75\%$	Biópsia
6	Biópsia prévia com malignidade confirmada	100%	—

Existem dois tipos de mamografias: a mamografia diagnóstica e a mamografia de *screening*. O primeiro tipo pode ser feito em qualquer idade, desde que a paciente esteja com suspeita de câncer de mama ou esteja inclusa no grupo dos pacientes com fatores de risco associados, descritos anteriormente. O segundo tipo deve fazer parte dos exames de rotina das mulheres, portanto pode ser feito em qualquer idade. No Brasil, as mulheres com idade entre 40 e 50 anos já são consideradas aptas para esse exame à rotina (VIEIRA, 2012).

Uma padronização das informações contidas nos laudos de exames de mamografia foi criada para que a interpretação fosse única em todo o mundo. O sistema *Breast Imaging Reporting and Data System* (BI-RADS), como pode ser visto na Tabela 1.1, foi criado pelo *American College of Radiology* (ACR) (RADIOLOGY, 2014) e é utilizado para estabelecimento de riscos inerentes ao paciente, prever a evolução da massa e orienta-lo para as próximas condutas que devem ser tomadas após o diagnóstico(VIEIRA, 2012).

1.1 MOTIVAÇÃO

A avaliação do exame de mamografia é feita por um radiologista especialista. Estatísticas apontam que os resultados são falhos entre 10% à 30% dos casos (SAMPAT; MARKEY; BOVIK, 2005). Em mulheres fora do grupo de risco, o exame de mamografia pode representar um risco em função do alto número de diagnósticos falsos-positivos ou de *overdiagnoses*[4] (TUPPER; HOLM, 2014). Ou seja, a sensibilidade inerente ao exame de mamografia pode, em alguns casos, interferir na expectativa de vida de um paciente e portanto, alguns fatores vêm sendo levantados pelos especialistas, colocando a eficácia do método em questão.

Em 1983, um estudo feito pela American Cancer Society (ACS) comprovou os benefícios e malefícios do exame. A partir desse estudo, a ACR estipulou que para mulheres que não estão no grupo de risco, a mamografia deve ser feita a cada 1 ou 2 anos em mulheres com idade entre 40 e 49 anos (TUPPER; HOLM, 2014).

[4]Termo em inglês para expressar o diagnóstico de um tumor que não levará o paciente ao óbito

Com o objetivo de aprimorar a acurácia[5] do exame de mamografia e consequentemente diminuir o número de falsos-positivos e falsos-negativos, foram desenvolvidos sistemas computacionais para auxiliar na análise desse raio-x (DOI, 2009). *Computer-Aided Detection* (CADe) e *Computer-Aided Diagnoses* (CADx) são *softwares* utilizados para auxiliar na detecção e diagnóstico de massas na mamografia, respectivamente. Para o primeiro tipo, os resultados oferecem a localização de massas na mamografia, apresentando ao radiologista uma base para que se possa refiná-las e desse modo, obter um diagnóstico mais coerente para o paciente. O segundo tipo, CADx, fornece um visão mais completa do exame. Através desses sistemas computacionais, o radiologista consegue saber o nível de malignidade da massa em questão.

A detecção e o diagnóstico do câncer de mama ainda são um desafio para os radiologistas em função da diversidade de formas e bordas das massas presentes na mamografia (JALALIAN et al., 2013). Apesar disso, as massas malignas em sua grande maioria, são representadas de forma espiculada[6]. Portanto, o principal objetivo de um sistema CAD é permitir que o radiologista ou o médico não tenham a necessidade de rever uma mamografia na qual não tenha sido encontradas massas anteriormente.

Os sistemas CADe são baseados em duas diferentes metodologias: os algoritmos aplicados *pixel*-a-*pixel* (*pixel-based*), onde operadores são aplicados em cada *pixel* da imagem que irão compor o vetor de *features*[7] para classificação e os algoritmos aplicados em uma determinada região de interesse (ROI) previamente segmentada para que posteriormente sejam extraídas as *features*.

A característica mais relevante dos métodos baseados em regiões está no fato de que, após a etapa de pré processamento, as imagens estarão englobando apenas a região de massa, sem que haja interferência das regiões de tecidos da mama e do próprio *background* da imagem de mamografia (SAMPAT; MARKEY; BOVIK, 2005). Promovendo um breve comparativo entre o custo computacional e o desempenho de ambos os métodos, pode-se perceber que apesar de ser um algoritmo de fácil implementação, o custo computacional dos métodos baseados em *pixel* são muito mais elevados se comparados com os métodos baseados em regiões.

Em (GORDON; RANGAYYAN, 1984) é desenvolvida uma metodologia baseada em *pixel* utilizando o aprimoramento do contraste da imagem a partir de uma determinada quantidade, fixa ou adaptativa, de *pixels* vizinhos. Para a determinação da melhor quantidade de *pixels* a serem fixados, uma função baseada no contraste e no tamanho da região central do *pixel* foi utilizada. Com isso, os valores de contraste aumentavam ao redor de regiões que formavam o *background* da imagem e consequentemente diminuam nas regiões centrais.

Além de massas espiculadas, o câncer de mama pode estar presente nas mamografias, na forma de pequenas e granuladas microcalcificações (STRICKLAND; HAHN, 1996). Entretanto, a detecção dessas pequenas regiões são difíceis em função da homogeneidade criada pela densidade do tecido da mama que aparece como *background* da

[5]Medida estatística que estabelece a relação entre um método e o número de resultados corretos que ele reproduz

[6]Massas com bordas irradiadas (DW POLLOCK RE, 2003)

[7]Termo em inglês para representar atríbutos extraídos a partir de uma imagem

imagem. Em (STRICKLAND; HAHN, 1996), um método utilizando transformadas de *wavelets*[8] bidimensionais é desenvolvido para detecção dessas microcalcificações. O algoritmo proposto utiliza uma transformada de *wavelet* como um banco para filtros de *multiscale matched*.

Em (KARSSEMEIJER; BRAKE, 1996) um método baseado em *pixel* para detecção dessas massas espiculadas foi desenvolvido. A proposta utiliza um mapa de orientação de *pixel*, onde duas *features* estatísticas, baseadas em operadores gaussianos, são utilizadas por um classificador Bayesiano para avaliar os padrões de bordas encontrados nas mamografias. O algoritmo conseguiu determinar 90% da malignidade das imagens da base de dados *Mammographic Image Analysis Society* (MIAS) (SUCKLING J. PARKER, 1994).

Utilizando os conceitos da *Support Vector Machine* (SVM), uma outra abordagem para detecção de microcalcificações é apresentada em (EL-NAQA et al., 2002). Foram utilizadas 76 mamografias, totalizando 1120 microcalcificações. Um dos principais problemas para detecção de microcalcificações utilizando classificadores está na etapa de treinamento. O número de mamografias que contêm microcalcificações é muito pequeno, tornando a etapa parcialmente falha. Como solução, os autores apresentam o algoritmo*successive enhancement-learning* que seleciona de maneira iterativa as melhores imagens de microcalcificações para treinamento da SVM. Os resultados apontaram uma sensibilidade acima de 94% para esse método. Sensibilidade é uma medida estatística para avaliar a quantidade de exames verdadeiramente positivos, levando em consideração os resultados obtidos através de um método de classificação específico.

(LI et al., 1995) desenvolveu uma nova abordagem de segmentação e para a detecção baseada em regiões de massas malignas em mamografias. A metodologia baseada no algoritmo *Markov Random Field* para segmentação utiliza os conceitos de multirresolução para que o processo ocorra de maneira mais eficaz e eficiente. Após a fase inicial, 18 *features* são extraídas das regiões e utilizadas pelo classificador *Fuzzy Binary Tree* para classificação das regiões. A sensibilidade do método foi de 94% com um total de 0.26 resultados falsos-positivos.

Em (LIU; BABBS; DELP, 2001) é apresentado um método para detecção de massas através da representação das mamografias em multi-resolução. Em uma primeira etapa, utilizando uma transformada de *wavelet* bidimensional, uma representação em multi-resolução é obtida para cada imagem. A partir dessas novas imagens, um conjunto de *features* é extraído para cada *pixel*. Todas as imagens, de baixas e altas resoluções, são utilizadas pela árvore binária para classificação. O algoritmo propõe ainda uma nova abordagem, delimitando o tamanho ideal da vizinhança para que sejam encontradas ROIs adequadas para classificação. Os resultados obtidos foram de 84.2% de malignidade das imagens da base de dados MIAS, para vários tamanhos de imagens.

Uma outra abordagem para seleção da região de interesse utilizando o contraste da imagem é apresentado em (KOBATAKE et al., 1999). O método é dividido em duas etapas, sendo a primeira o desenvolvimento do algoritmo *iris filter*, que consegue fazer a extração da região de interesse baseado no contraste entre ela e o seu *background* e na

[8] Funções de decomposição de sinal em funções bases

segunda etapa é feita a extração das *features* que possuem uma boa capacidade de distinção, ou seja, que consigam estabelecer a diferença entre ROIs malignas e benignas.

Em alguns métodos para detecção de massas em mamografias, a saída do algoritmo se restringe a delimitação das bordas da massa na mamografia e portanto, a classificação em benigna e maligna deverá ser feita por outro método. O objetivo para a implementação de um sistema CADx se baseia na classificação de uma região de interesse (ROI) a partir de um conjunto de *features* extraídas e, consequentemente, retornam como saída a porcentagem de malignidade de uma determinada ROI. A ideia principal desses algoritmos é baseada nas observações dos radiologistas a cerca das diferenças entre massas e tecidos normais, avaliar estatisticamente as *features* extraídas dessas novas imagens.

Métodos baseados em redes neurais vêm sendo utilizados para classificação de massas em mamografias. Em (KUPINSKI; GIGER, 1997) é apresentada uma nova abordagem, onde o principal objetivo é a minimização do problema de *over-trainning*[9] eminente nesse método. Todas as mamografias utilizadas tiveram seus resultados testados a partir de uma biópsia.

As *features* de Haralick (HARALICK; SHANMUGAM; DINSTEIN, 1973) vêm sendo utilizadas para classificação de texturas em imagens de mamografias. Em (MUDIGONDA; RANGAYYAN; DESAUTELS, 2000), utilizando um método modelagem poligonal de *features* para extrair os pixels ao redor das margens da massa para a extração das *features* baseadas em gradiente e a partir das matrizes de co-ocorrência (GLCM) das imagens foram extraídas as *features* de Haralick. Foram utilizadas 54 imagens, sendo 28 benignas e 26 malignas.

(LI; CLARK; THOMAS, 2001) apresenta um método para diagnóstico de massas em imagens de mamografias digitais. A princípio, com o objetivo de tornar a base de dados mais uniforme, é feito um pré processamento das imagens com a extração das ROIs das mamografias, redução de ruídos e a normalização da intensidade dos *pixels* em cada mamografia. Em seguida, utilizando a transformada de *wavelet* direcional, duas *features* da imagem são extraídas: textura direcional com *line-based features* e uma versão suavizada da imagem original com *region-based features*. Por conta da variação na forma, borda e tamanho das massas, foi utilizado uma representação em multiescala para extração de *features* que contemplem todos os tipos de variação de massa. Os resultados obtidos através do classificador híbrido mostraram uma sensibilidade de 91% para esse método.

Em (TOURASSI et al., 2003) um método para diagnóstico de regiões de interesse em mamografia é desenvolvido utilizando o conceito de *knowledge-based CAD* (KB-CAD). A partir da base de dados, foram selecionadas mamografias com massas benignas (146 casos), malignas (260 casos) e mamografias sem massas (82 casos). Após a seleção, a extração foi feita baseada nas informações de contornos disponíveis na própria base de dados. ROIs de tamanho 512×512 *pixels* foram extraídas de cada caso. Utilizando um algoritmo de *template matching*, cada nova ROI é comparada com uma região suspeita de malignidade. Em casos onde ocorre a similaridade entre as duas regiões, a imagem

[9] Termo em inglês para designar o treinamento excessivo do classificador

é arquivada para a etapa final, onde um algoritmo de decisão irá predizer se a região é classificada como maligna ou benigna.

Uma nova abordagem para detecção e diagnóstico de câncer de mama utilizando a variação do contraste dos *pixels* da imagem é apresentado em (WANG et al., 2013).As imagens utilizadas eram de 8-bits e possuíam tamanho fixo de 1024×1024. Após a remoção dos tecidos adiposos e glândulas parciais da mamografia, as imagens foram submetidas ao procedimento de *running filter*, realçando as glândulas suspeitas e atenuando a aparência dos tecidos saudáveis.

Os sistemas CADe e CADx vêm sendo aprimorados com o objetivo de aumentar a porcentagem de acurácia e consequentemente diminuir a quantidade de laudosfalsos-positivo. Segundo (CHENG et al., 2003), em mulheres onde o tumor maligno é descoberto previamente, a taxa de sobrevivência é de 82%, em contrapartida, para as neoplasias detectadas em estágio avançado esse número cai para 60%.

1.2 OBJETIVO PRINCIPAL

O objetivo principal desse trabalho é fazer uma análise comparativa entre os resultados de classificação de massas e não massas através da extração da Entropia de Tsallis calculada a partir das matrizes de co-ocorrência e da Decomposição em Valores Singulares (SVD) de cada imagem presente na base de dados *Digital Database Mammography Screening* (DDSM)(HEATH, 1998). Desse modo, o resultado final desse trabalho prevê a implementação de uma nova ferramenta CADe para auxiliar os radiologistas no fornecimento de laudos mais precisos, ou seja, com o menor número possível de falsos-positivos, para os pacientes que ainda se encontram em estágio inicial da doença.

1.3 ORGANIZAÇÃO

Esse trabalho está organizado de acordo com a seguinte ordem. No Capítulo 2, será apresentada a revisão bibliográfica fundamental para o entendimento dos demais capítulos. A priori, são estabelecidos os principais conceitos sobre a mama feminina e sobre a patologia do câncer de mama. Em seguida, são apresentadas as características da mamografia, nosso principal objeto de estudo desse trabalho, ressaltando quais propriedades deverão ser levadas em consideração no momento da implementação de algoritmos para o processamento dessas imagens. São apresentados também os fundamentos do processamento de imagens, definição de uma imagem digital, descrição de técnicas de realce da imagem, como a equalização de histograma e a etapa final de extração da região de interesse contida em cada mamografia. Após, são descritos os conceitos do reconhecimento de padrões, com as definições de textura e a apresentação dos principais classificadores utilizados em sistemas CADx e CADe. Por último, são apresentados os conceitos dos métodos que serão utilizados para extração de características. Definiremos o que é uma matriz de co-ocorrência e quais features poderão ser extraídas a partir dela. Além de apresentar as definições matemáticas para a decomposição em valores singulares e de que maneira essas matrizes, juntamente com a Entropia de Tsallis podem auxiliar na classificação de ROIs de massa e não massa em

mamografias.

No Capítulo 3, serão descritos todos os passos que foram seguidos para montar a metodologia desse trabalho. Esse capítulo foi dividido de forma temporal. Inicialmente é descrita a fase de aquisição das imagens, descrevendo sobre as características da base de dados escolhida (DDSM), como as mamografias foram pré processadas para obter os melhores resultados e por fim, será apresentado os critérios para extração das regiões de interesse.

A aplicação dos métodos para diagnóstico também serão apresentados nessa seção. Inicializando com a implementação dos métodos para criação das matrizes de co-ocorrência para quatro diferentes direções θ, onde $\theta \in \{0°, 45°, 90°, 135°\}$ e para quatro distâncias d diferentes, onde $d \in \{1, 2, 3, 4\}$. São apresentadas também, a metologia utilizada para implementação do método de decomposição em valores singulares, e de que maneira os conceitos de valores singulares das matrizes de co-ocorrência da imagem na construção desses diversos conjuntos de *features*. Por fim, são descritas todas as características da biblioteca libSVM (CHANG; LIN, 2011), um classificador baseado em SVM, utilizado nesse trabalho para obtenção das 5 métricas de avaliação dos sistemas de detecção de massas e não massas: acurácia, sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo.

O Capítulo 4 apresenta todos os resultados obtidos a partir da aplicação das metodologias previamente descritas no Capítulo 3 e elabora uma análise comparativa entre esses resultados utilizando as métricas encontradas para a GLCM e para a SVD. Por último, no Capítulo 5 são apresentadas as conclusões finais desse trabalho, ressaltando as vantagens e desafios encontrados para a implementação das metodologias. Além disso, nesse capítulo serão apresentadas os principais tópicos para a elaboração de um trabalho posterior.

Capítulo

2

Neste capítulo são abordados todos os conceitos teóricos que foram utilizados para o desenvolvimento desse trabalho. Inicialmente, são descritos os conceitos anatômicos da mama feminina e os conceitos patológicos que envolvem o câncer de mama. Em seguida, serão descritos os principais fundamentos do processamento de imagem e do reconhecimento de padrões. Serão estabelecidos, por fim, todos os conceitos aplicados nas metodologias utilizadas para criação do conjunto de features, sendo elas: matriz de co-ocorrência, a decomposição em valores singulares e entropia de Tsallis

FUNDAMENTAÇÃO TEÓRICA

2.1 ANATOMIA DA MAMA FEMININA

O conhecimento histológico e anatômico da mama feminina auxilia o radiologista ou o médico na confecção do laudo do paciente, aumentando assim, as chances de um resultado coerente (JESINGER, 2014). Desde a forma embrionária até o ínicio da puberdade, a mama feminina e masculina não apresentam diferenças (ELLIS; MAHADEVAN, 2013). A partir da quinta semana de gestação, os primeiros lóbulos mamários começam a ser formados. Entretanto, os nervos, os ligamentos, as artérias, as veias, a gordura e o sistema linfático da mama só serão formadas após a gestação (JESINGER, 2014). Durante esse período, os ductos começam a se proliferar pela mama, formando em suas terminações, o que posteriormente darão origem aos lóbulos mamários (ELLIS; MAHADEVAN, 2013).

Ao final da puberdade, na fase adulta, a mama feminina já está composta por inúmeros ductos, tecidos de estroma glandular, gordura, lóbulos e estruturas neurovasculares posicionadas sobre a caixa torácica, como pode ser visto na Figura 2.1. Após os 40 anos, o tecido lobular e os ductos começam a atrofiar, ocasionando a regressão do tecido glandular e a reposição do mesmo pela gordura e tecido conectivo[10].

Os ductos são estruturas complexas e heterogêneas, responsáveis pela passagem do leite até os mamilos. Estima-se que cerca de 4 a 18 ductos são responsáveis por essa transmissão. O comprimento da mama feminina se estende da segunda costela até a sexta, e a pele que cobre a mama é conectada com o tecido interior através de uma camada facial (JESINGER, 2014). O tamanho e a forma da mama nem sempre podem

[10]Tecido composto de células e fibras em uma matriz de proteínas

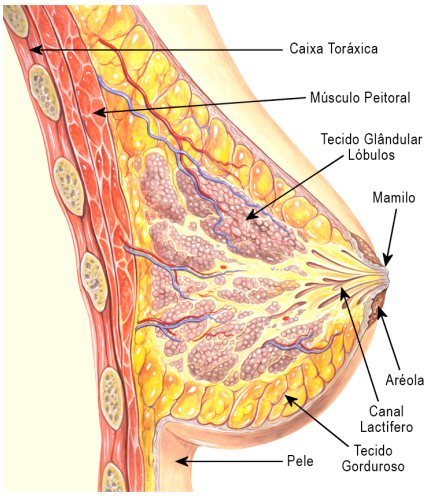

Figura 2.1 Estrutura da mama feminina na maturidade
Fonte: (TECHNOLOGY, 2015)

ser determinadas pela quantidade de tecido glandular interno presente na mesma. Durante a gravidez, a mama feminina pode dobrar a quantidade de glândulas ativas em função das atividades de lactância, e por consequência pode existir uma variação no tamanho da mama.

2.2 CÂNCER DE MAMA

O câncer de mama é uma neoplasia heterogênea, e portanto vários fatores podem influenciar no desenvolvimento da doença, como fatores genéticos e relacionados ao estilo de vida. De acordo com (ECONOMOPOULOU; DIMITRIADIS; PSYRRI, 2015), 5% à 10% dos casos de câncer de mama são hereditários e dessa porcentagem 30% foram desenvolvidos através de mutações nos genes BRCA[11] 1 e 2.

A neoplasia se desenvolve a partir de alterações no DNA que provocam uma grande quantidade de lesões genéticas, levando assim a inibição dos genes capazes de impedir o surgimento de tumores, gerando as alterações fenotípicas que acarretarão no surgimento do câncer de mama (VIEIRA, 2012). O carcinoma é a neoplasia maligna mais frequente na mama. Esse tipo de tumor pode ser classificado como *in situ*, que geralmente é detectado na mamografia de *screening*, ou classificado como carcinoma invasivo.

O carcinoma *in situ* pode estar localizado na massa mamária ou ainda nas mediações do mamilo. O tumor provoca a proliferação do epitélio neoplásico dentro dos ductos da mama, podendo estender-se até os lóbulos (BATEMAN, 2006). Esse tipo de neoplasia, quando não ocorre em associação com o carcinoma invasivo, geralmente não apresenta risco de desenvolver metástase[12] e, por consequência, poderá ser tratada através da remoção do tumor por cirurgia. A grande questão, ainda não respon-

[11]Genes responsáveis pelo impedimento de desenvolvimento de tumores
[12]Processo de disseminação do tumor por outros órgãos do corpo do paciente

dida pelos médicos, está relacionada com o tamanho do corte que deve ser feito na mama para que o tumor não volte a se desenvolver após o procedimento. Até o momento, acredita-se que uma margem de 10mm seja suficiente (BATEMAN, 2006). Em alguns casos, onde o tumor já se estendeu por grande parte da mama, a mastectomia[13] é o procedimento mais adequado.

2.3 MAMOGRAFIA

Para a detecção prévia do câncer de mama, é recomendada a utilização de exames de raio-X, como a mamografia de *screening* e a ultrassonografia da mama. A mamografia, por sua vez, é a ferramenta mais utilizada para descrição da região mamária (JESINGER, 2014), produzindo uma imagem em alta definição, com o objetivo de proporcionar ao radiologista uma melhor visão da mama da paciente. No raio-x, os tecidos glandulares aparecem com a cor branca, bem como a pele que aparece como uma linha branca. Já os tecidos que representam a gordura aparecem em um tom de cinza mais escuro, tornando a visualização e percepção do radiologista mais fácil.

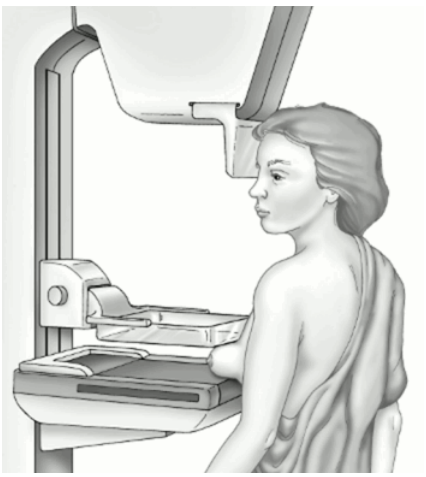

Figura 2.2 Esquema ilustrativo do exame de mamografia
Fonte: (RADIOLOGY, 2014)

O exame é feito através do mamógrafo, a partir da compressão da mama por alguns segundos (Figura 2.2). Estatísticas apresentadas em (BARTH; GIBSON, 2005) revelaram que o exame de mamografia consegue identificar pequenas massas malignas, que proporcionam ao paciente um tratamento menos doloroso em comparação com o exame clínico, que quando aplicado de maneira isolada só consegue identificar a neoplasia em estágio avançado, fazendo com que o paciente necessite passar por procedimentos invasivos, como a quimioterapia[14].

O procedimento pode ser elaborado utilizando duas diferentes visões da mama, como pode ser visualizado na Figura 2.3. A visão cranio-caudal é obtida por radiação de raios-x sobre a mama, na direção vertical (ver Figura 2.3(a)). A visão médio

[13]Remoção completa da região interna da mama da paciente
[14]Tratamento para o câncer através de manipulação de substâncias químicas

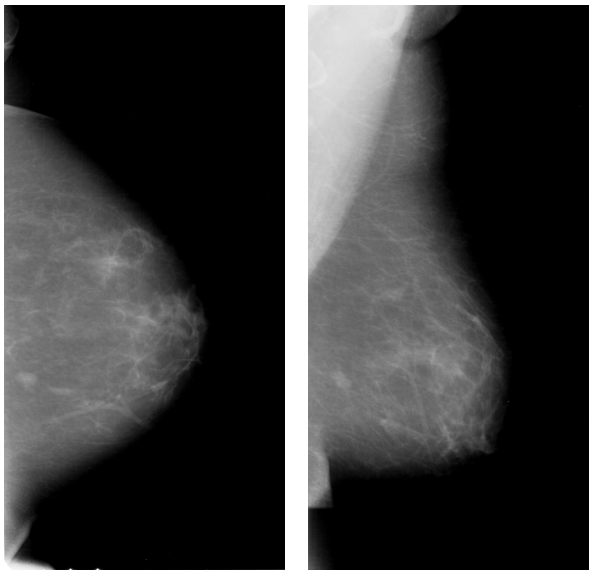

(a) (b)

Figura 2.3 (a) Mamografia utilizando a visão crânio-caudal; (b) Mamografia utilizando a visão médio lateral oblíquia (MLO)

Fonte: (HEATH, 1998)

lateral oblíqua é obtida por radiação de raios-x sobre a mama, segundo um ângulo previamente determinado (ver Figura 2.3(b)). É sabido que, até hoje, o exame de mamografia é o exame de *screening* que retorna os melhores resultados para a detecção de câncer de mama em fases iniciais, sendo o único exame de *screening* que consegue reduzir a taxa de mortalidade no mundo (DRUKTEINIS et al., 2013).

Entretanto, de acordo com (CARNEY et al., 2003), a sensibilidade[15] e a especificidade[16] da mamografia estão diretamente associadas à densidade da mama da paciente, ou seja, em mulheres com idade entre 50 e 79 anos, onde a densidade da mama é alta, a mamografia não atinge uma porcentagem de acurácia[17] satisfatória para diagnóstico do câncer de mama. Por outro lado, em mulheres com idade acima de 80 anos, esse método vêm sendo bastante eficaz.

O número de resultados falsos-positivos[18] ainda é uma grande preocupação para a comunidade médica. A partir do laudo incorreto, o paciente poderá se submeter à outro exame de mamografia, o que aumentaria a taxa de radiação na qual ele estaria sendo exposto, ou ainda seria necessário a realização de uma biópsia (DRUKTEINIS et al., 2013). Por esse motivo, com o avanço tecnológico, novas ferramentas CADe (sistemas para detecção de massas) e CADx (sistemas para diagnóstico de massas) estão sendo desenvolvidas com o intuito de aumentar a acurácia do exame de mamografia.

[15]Capacidade de identificar indivíduos doentes

[16]Capacidade de identificar indivíduos sadios

[17]Capacidade de estimar diagnósticos corretos (positivos e negativos). Ou seja, apresenta a relação entre os valores de sensibilidade e especificidade

[18]Resultado positivo para um paciente que está sadio

2.4 FUNDAMENTOS DO PROCESSAMENTO DE IMAGENS

O principal objetivo para o estudo da análise e processamento digital de imagens é apresentado através de duas vertentes: melhoramento das imagens para que o ser humano consiga interpretar de maneira mais adequada; e o processamento das imagens para armazenamento, transmissão e representação de forma automatizada (GONZALEZ; WOODS, 2002).

Podemos definir o processamento de imagens digitais como sendo um conjunto de passos que se inicializam na aquisição da imagem e terminam com o reconhecimento de objetos. Através dessas etapas, a imagem passa por várias alterações para ser adaptada para um determinado problema em questão. O fluxograma descrito na Figura 2.4 ilustra de maneira simplificada as etapas fundamentais.

Figura 2.4 Fluxograma simplificado das etapas do Processamento Digital de Imagens
Fonte: (GONZALEZ; WOODS, 2002)

2.4.1 Aquisição e representação da imagem digital

Uma imagem é definida como uma função bidimensional $f(x, y)$, onde x e y são as coordenadas espaciais e a amplitude f representará a intensidade do pixel no ponto (x, y), como pode ser visto na Equação (2.1). Uma imagem digital pode ser descrita então, por um conjunto finito de elementos, chamados de *pixels*, onde cada um possui um valor específico e uma localização única (GONZALEZ; WOODS, 2002).

$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,N-1) \\ f(1,0) & f(1,1) & \dots & f(1,N-1) \\ \vdots & \vdots & \ddots & \vdots \\ f(M-1,0) & f(M-1,1) & \dots & f(M-1,N-1) \end{bmatrix} \tag{2.1}$$

Um *pixel* de coordenada (x, y) possui quatro vizinhos (horizontais e verticais), chamados de 4-vizinhança e representados através da notação $N_4(p)$, sendo p o *pixel* em questão. Além disso, um *pixel* possui ainda outros quatro vizinhos, nas diagonais, que em conjunto com os *pixels* da 4-vizinhança, formarão a 8-vizinhança, representada pela notação $N_8(p)$.

As imagens digitais são formadas a partir da captação da energia através de sensores (Figura 2.5). De maneira genérica, podemos descrever essa formação a partir da convolução entre uma determinada fonte de iluminação e a absorção dessa energia por todos os elementos que fazem parte da cena daquela imagem (GONZALEZ; WOODS, 2002). A aquisição das imagens pode ser feita utilizando dois tipos de sensores: por linha e por aquisição matricial.

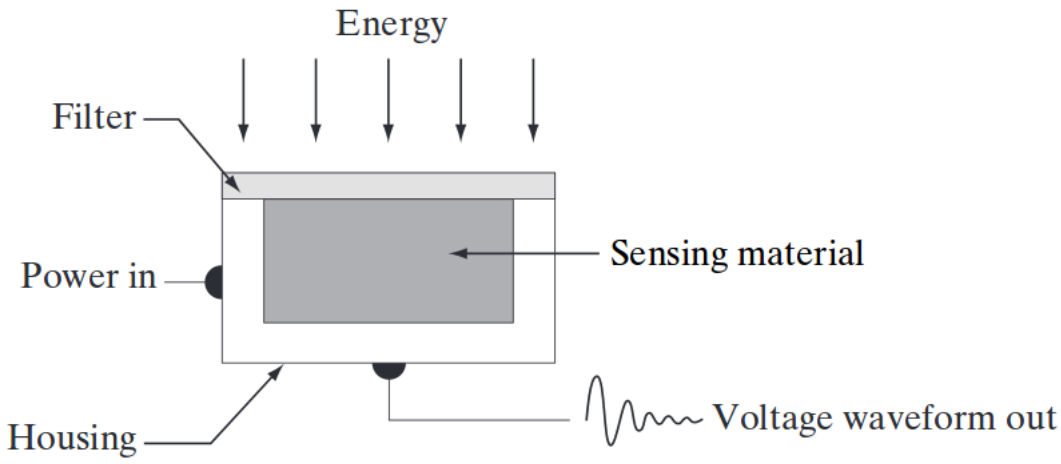

Figura 2.5 Exemplo de um sensor para aquisição de imagem
Fonte: (GONZALEZ; WOODS, 2002)

A varredura por linha, geralmente é aplicada pelos *scanners* de mesa e fornecem, a cada varredura, uma linha da imagem que se deseja capturar. Para imagens médicas, os sistemas de sensores por varredura de linha são dispostos em forma de anel, para obtenção de uma imagem de corte transversal[19].

A aquisição feita através de sensores matriciais são geralmente instalados em dispositivos de câmeras digitais. A principal vantagem desse método de aquisição é a possibilidade de projeção do padrão de energia diretamente na superfície da matriz, dessa forma não há necessidade de movimentação do arranjo de sensores.

2.4.2 Equalização de Histograma

O histograma de uma imagem em escala de cinza pode ser representado através da função discreta representada na Equação (2.2):

$$h(r_k) = n_k \tag{2.2}$$

onde k representa o k-ésimo nível de intensidade de cinza, dado um intervalo de níveis de cinza $[0, L-1]$ (sendo que L corresponde a quantidade de níveis de cinza da imagem), e n_k representará o número total de *pixels* naquela imagem compartilhando o nível de cinza r_k. Em sua representação gráfica, o eixo horizontal corresponderá aos valores de intensidade r_k e o eixo vertical à função de histograma descrita na Equação (2.2).

Sabendo que r_k representa o valor de intensidade de um *pixel* em um ponto específico de coordenadas (x, y), a equalização de histograma é o mapeamento dessas

[19]Corte transversal disponibiliza ao usuário uma seção do objeto tridimensional (GONZALEZ; WOODS, 2002)

intensidades através da Equação (2.3):

$$s = T(r) \quad 0 \leq r \leq L - 1 \tag{2.3}$$

de maneira que os níveis de cinza s compartilhem aproximadamente o mesmo número de *pixels*. Os níveis de cinza de uma imagem podem ser considerados como variáveis aleatórias dentro do intervalo $[0, L-1]$. Dessa forma, podemos utilizar uma função densidade de probabilidade (PDF) para fazer a representação dessas variáveis. Supomos então que $p_r(r)$ e $p_s(s)$ são as PDFs, diferentes, das variáveis r e s, respectivamente. Na Figura 2.6 é ilustrado o processo de equalização do histograma em uma região de interesse (ROI).

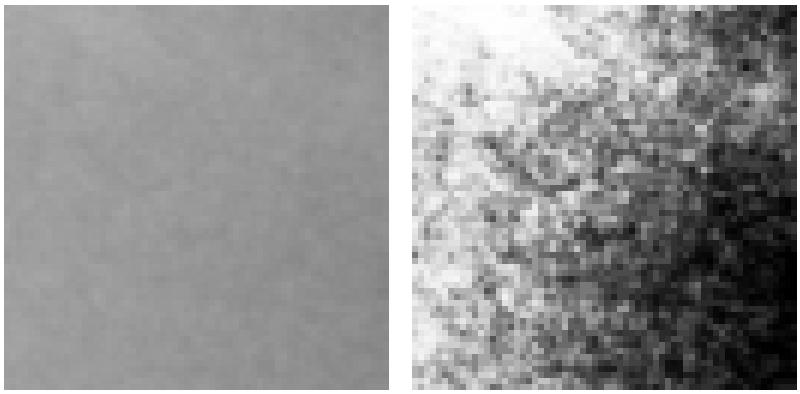

(a) (b)

Figura 2.6 (a) Imagem do nódulo mamário sem equalização de histograma (b) Imagem do nódulo mamário com equalização de histograma

Para valores discretos, como é o caso dos níveis de cinza de uma imagem, pode-se representar essas PDFs em forma de somatório. Desse modo, calcula-se a probabilidade da frequência de um nível de cinza em uma determinada imagem f de dimensão $M \times N$, como sendo:

$$p_r(r_k) = \frac{n_k}{M \times N} \tag{2.4}$$

onde n_k é o número total de *pixels* com a intensidade r_k e $M \times N$ o número total de *pixels* da imagem. Consequentemente, a fórmula discreta que representará a equalização de histograma de uma imagem será:

$$s_k = T(r_k) = (L-1) \sum_{i=0}^{k} p_r(r_i) = \frac{(L-1)}{M \times N} \sum_{i=0}^{k} n_i \tag{2.5}$$

O processo de equalização pode então ser descrito como a obtenção de um novo *pixel* de saída através do mapeamento do *pixel* de entrada r_k em seu correspondente nível s_k com o auxílio da Equação (2.5).

2.4.3 Quantização de imagens

Uma imagem digital é representada através de um conjunto finito de valores binários. Dessa forma, para transformação de uma imagem real em uma imagem digital, é necessário a utilização de dois processos: amostragem e quantização. O primeiro processo consiste na representação discreta da imagem e o segundo processo consiste na seleção dos valores dos *pixels* de cada ponto previamente amostrado.

Existem inúmeros métodos para quantização de imagens. Um quantizador pode ser descrito como um transformador de um sinal contínuo em um sinal discreto para um dado intervalo finito de números. Uma imagem real, também chamada de sinal contínuo, possui valores contínuos para as coordenadas (x, y) e para os valores de amplitude associados à cada um desses ponto.

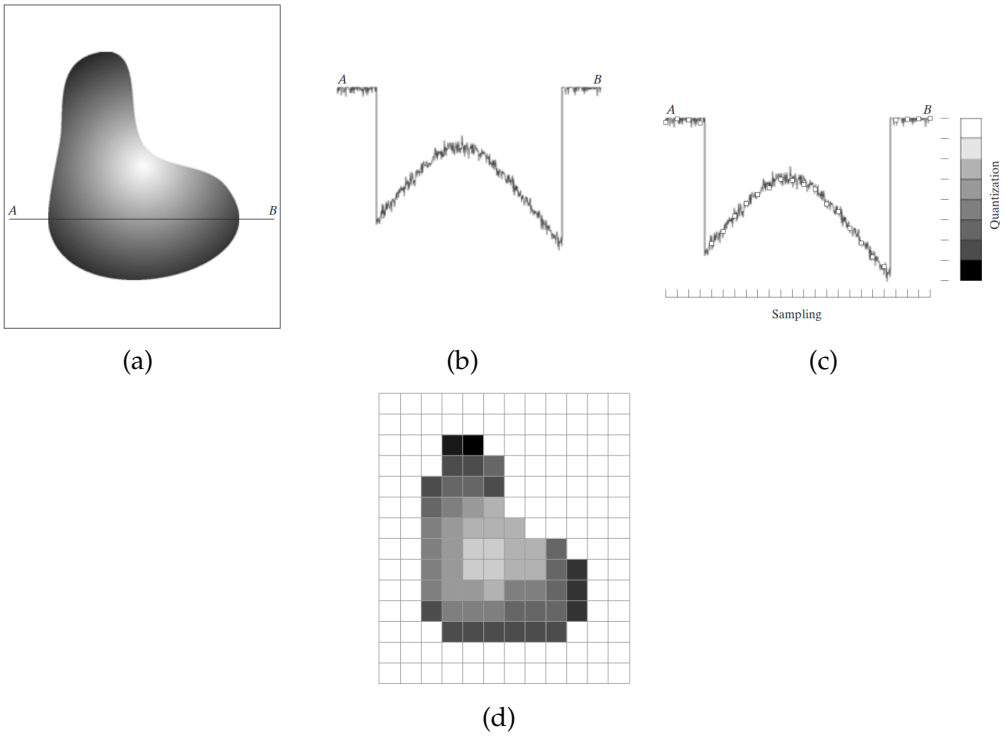

Figura 2.7 (a) Seleção de um segmento $\overline{AB}$ da imagem (b) Representação contínua do segmento $\overline{AB}$ (c) Processo de amostragem e quantização do segmento $\overline{AB}$ (d) Imagem original quantizada

Source: (HEATH, 1998)

A Figura 2.7(a) apresenta uma imagem real (sinal contínuo) representada através de um sensor. A partir dessa imagem, um segmento $\overline{AB}$ foi selecionado para avaliação das etapas de amostragem e quantização dos pontos presentes nesse segmento. Na Figura 2.7(b) é apresentado um gráfico dos valores contínuos do segmento $\overline{AB}$. Em sequência, as etapas de amostragem e quantização pode ser exemplificada através da Figura 2.7(c), onde os quadrados brancos representam a localização das amostras dos níveis de cinza.

O processo final consiste na quantização dessas regiões de amostragem. Ainda na Figura 2.7(c) é apresentada uma região de quantização na lateral direita, representando uma escala de cinza com oito variações de tonalidade. Através dessa divisão, é possível verificar, a partir da posição das amostras, quais serão os valores de níveis de cinza atribuídos a cada região. Por fim, a Figura 2.7(d) apresenta a imagem original completamente amostrada e quantizada.

2.4.4 Descrição da imagem

Uma determinada região da imagem, separada previamente, pode ser representada de duas formas: através de suas fronteiras ou através dos *pixels* que compõem sua região interna. A primeira representação deve ser escolhida quando o objetivo principal é conservar as propriedades da forma da imagem. E a segunda representação, quando o objetivo for a conservação das propriedades internas da imagem.

Para que os algoritmos de fronteira consigam percorrer toda a borda da imagem, é necessário que os *pixels* estejam ordenados no sentido horário ou anti-horário. Portanto, como passo inicial para aplicação desse método, um algoritmo de ordenação deve ser utilizado (GONZALEZ; WOODS, 2002). Se a região interna for conhecida, o algoritmo de rastreamento de fronteira também funcionará de maneira adequada, extraindo as fronteiras de uma determinada região binária.

2.4.4.1 Chain Code A partir de 4 ou 8-vizinhanças, a técnica de *Chain Code* fornece uma sequência conectada e ordenada de segmentos de reta, aproximantes da fronteira da região, segundo uma direção especificada (GONZALEZ; WOODS, 2002). Essa direção será então codificada através de um esquema de numeração.

Em (FREEMAN, 1974), um comparativo sobre diversas abordagens de *Chain Code* são apresentados. Cada *pixel* é então representado pelos oito *pixels* ao redor dele. Para o esquema de numeração, (FREEMAN, 1974) apresenta uma codificação de 0 à 7, como pode ser visualizado na Figura 2.8 e seguindo a direção no sentido horário, é possível então representar as imagens através da sequência de dígitos octais.

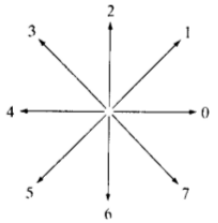

Figura 2.8 Codificação de 8 direções para o *Chain Code*
Fonte: (GONZALEZ; WOODS, 2002)

Após o processo de aquisição e pré-processamento, uma imagem é representada através de uma grade com um espaçamento igual em todas as direções das coordenadas (x, y) (GONZALEZ; WOODS, 2002).

Em (LIU; ŽALIK, 2005), uma nova abordagem para representação do *Chain Code* utiliza os princípios do Código de Huffman (HUFFMAN, 1952) para simplificar a representação da fronteira de uma imagem. A construção do novo código da cadeia é feita através de dois passos: no primeiro, o *Chain Code* da imagem, proposto em (FREEMAN, 1974), é criado. Em seguida, são avaliadas as diferenças angulares entre um ponto no código e seu antecessor. A partir disso, é montada uma tabela de frequências dessas variações angulares, para que a codificação de Huffman seja utilizada para representar essa fronteira, em binário, partindo do princípio de que, um elemento que ocorre com maior frequência será representado pelo menor valor em binário (0) e, por indução, as variações angulares de menor frequência serão representados pelo maior valor em binário para aquela sequência de oito direções (1111111).

2.5 MATRIZ DE CO-OCORRÊNCIA

A partir da definição fundamental do processamento digital de imagens, na qual uma função $f(x, y)$ representa a intensidade de um *pixel* na posição (x, y) de uma imagem, (HARALICK; SHANMUGAM; DINSTEIN, 1973) propôs uma nova abordagem para representação da imagem e extração de características.

2.5.1 Definição algébrica

Sabendo que $L_x = \{1, 2, 3 \ldots, N_x\}$ e $L_y = \{1, 2, 3, \ldots, N_y\}$ representam os domínios espaciais de X e Y, respectivamente. Portanto, o produto cartesiano $L_x \times L_y$ é a descrição do conjunto de *pixels* de uma determinada imagem f a partir de um valor de intensidade no conjunto $\{1, 2, 3, \ldots, N_g\}$, onde N_g é o valor total de níveis de cinza daquela representação. A imagem f pode ser representada como uma função que atribui a cada célula da imagem, um valor de intensidade, como mostra a Equação (2.6):

$$f : L_x \times L_y \rightarrow R_g \tag{2.6}$$

onde $R_g = \{1, 2, 3, 4, \ldots, N_g\}$

As dimensões das matrizes de co-ocorrência[20](GLCM) são definidas a partir da quantidade de níveis de cinza na imagem $N_g \times N_g$, onde N_g representa o número total de níveis de cinza da imagem. Ou seja, quanto maior o nível de cinza, maior será a dimensão da matriz de co-ocorrência.

Analisando sobre o ponto de vista do desempenho computacional, o número de operações que serão feitas nas matrizes de co-ocorrência é, por muitas vezes, maior do que para a própria imagem, e o custo computacional é alto. O objetivo então é definir alguns descritores que serão extraídos das matrizes de co-ocorrência e, a partir dessas medidas, estabelecer as relações de textura para a classificação das imagens ou de regiões dela. Desse modo, (HARALICK; SHANMUGAM; DINSTEIN, 1973) definiram 14 medidas que são utilizadas para extração de características inerentes à uma imagem.

[20]Termo em inglês *gray level cooccurrence matrix* (GLCM)

As matrizes de co-ocorrência são montadas a partir da relação ângular entre um *pixel* e seu vizinho mais próximo. Essa matriz de frequências poderá ser representada por P_{ij}, onde cada posição da matriz corresponderá à uma frequência de ocorrência de dois *pixels* vizinhos satisfazendo uma distância d predefinida, um ângulo $\theta \in \{0°, 45°, 90°, 135°\}$ e, i e j representarão os níveis de cinza. Genericamente, podemos definir uma matriz de co-ocorrência a partir da Equação (2.7).

$$P_{ij} = P(i,j;d,\theta) = \#\left\{ \begin{array}{r} [(x_1,y_1),(x_2,y_2)];\ x_2 - x_1 = d.cos\ \theta, y_2 - y_1 = d.sen\ \theta, \\ f(x_1,y_1) = i\ e\ f(x_2,y_2) = j \end{array} \right\} \quad (2.7)$$

onde (x_1, y_1) e (x_2, y_2) são *pixels* na região de interesse (ROI), $f(\cdot,\cdot)$ é o nível de cinza do *pixel*, e $\#[(\cdot,\cdot),\ (\cdot,\cdot)]$ denota o número de pares de *pixels* que satisfazem as condições listadas. A Figura 2.9 apresenta quatro diagramas correspondentes às quatro direções θ para o cálculo da GLCM.

As matrizes de co-ocorrência propostas por (HARALICK; SHANMUGAM; DINSTEIN, 1973) possuem algumas propriedades importantes para o desenvolvimento do conceito de análise de textura. Pode-se perceber, a partir da Equação (2.7), que as matrizes são simétricas, ou seja $P(i,j;d,\theta) = P(j,i;d,\theta)$, e por isso a complexidade do algoritmo para o cálculo dessas matrizes diminui consideravelmente.

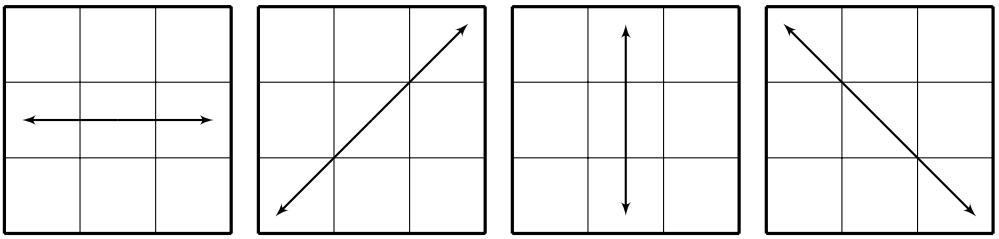

Figura 2.9 (a) GLCM para $\theta = 0°$ (b) GLCM para $\theta = 45°$ (c) GLCM para $\theta = 90°$ (d) GLCM para $\theta = 135°$

2.5.2 Aplicações da GLCM

O trabalho desenvolvido em (KHUZI et al., 2009) apresenta um sistema CADx para classificação de massas normais e anormais utilizando *features* extraídas a partir da matriz de co-ocorrência. Para o desenvolvimento dos experimentos, foram utilizadas 100 imagens de mamografias da base de dados MIAS. Inicialmente, as imagens foram equalizadas utilizando a técnica de equalização de histograma adaptativa baseada no limite de contraste (CLAHE) e em seguida foram utilizados três algoritmos de segmentação com o objetivo de comparar os resultados e avaliar qual a melhor escolha para auxiliar no processo de classificação. O primeiro algoritmo foi o de *threshold*[21] local, onde um valor limite é selecionado e todos os *pixels* da imagem são comparados com

[21] Termo em inglês para limiar

ele. Se o valor do *pixel* for maior que o valor limite, o *pixel* assumirá o valor de 255 na escala de cinza (correspondente a cor branca). O segundo algoritmo desenvolvido foi o *K-means clustering*, onde foram feitos testes para descobrir qual o melhor número de *clusters* para obtenção de um resultado favorável para classificação de mamografias. O melhor resultado foram 4 *clusters*.

Por fim, o último algoritmo de segmentação implementado em (KHUZI et al., 2009) foi a segmentação de Otsu (OTSU, 1979). Para a próxima etapa, de extração de *features*, foram utilizadas as matrizes de co-ocorrência, calculadas a partir de imagens de tamanhos 8×8, 16×16 e 32×32, com uma distância $d = 1$ e quatro direções θ, onde $\theta \in \{0°, 45°, 90°, 135°\}$. As *features* de Haralick calculadas foram: energia, homogeneidade, contraste e correlação. Ao final, o melhor resultado obtido foi através da segmentação de Otsu, onde a área calculada abaixo da curva ROC foi igual à 0.84.

Tabela 2.1 Tabela de fórmulas de *features* utilizadas em (NITHYA; SANTHI, 2011a)

Nome da categoria	Significado
Energia	$\sum_{i,j=0}^{G-1} P(i,j)^2$
Entropia	$-\sum_{i,j=0}^{G-1} P(i,j)\log(P(i,j))$
Homogeneidade	$\sum_{i,j=0}^{G-1} \frac{P(i,j)}{1+\|i-j\|}$
Correlação	$\sum_{i,j=0}^{G-1} \frac{P(i,j)(i-\mu_i)(j-\mu_j)}{\sigma_i \times \sigma_j}$
Soma dos quadrados da variância	$\sum_{i,j=0}^{G-1} P(i,j)(i-\mu)^2$

Em (NITHYA; SANTHI, 2011a) é apresentada uma nova abordagem para classificação de massas em mamografias envolvendo também os conceitos de matriz de co-ocorrência. A partir dessas matrizes de co-ocorrência calculadas a partir das imagens extraídas da base de dados DDSM (HEATH, 1998), (NITHYA; SANTHI, 2011a) propôs a extração de apenas cinco *features* (entropia, energia, homogeneidade, correlação e soma dos quadrados das variâncias), como pode ser visto na Tabela 2.1 e, posteriormente, a classificação desses resultados através de uma rede neural de três camadas. Para os experimentos (NITHYA; SANTHI, 2011a) utilizou 250 imagens de mamografia, onde para cada uma foram criadas 16 matrizes, com variação angular de $\theta \in \{0°, 45°, 90°, 135°\}$ e distância $d \in \{1, 2, 3, 4\}$.

Em (NITHYA; SANTHI, 2011c), é apresentado um método para classificação de mamografias através de 18 *features* para descrição de texturas. Através dos resultados apresentados, (NITHYA; SANTHI, 2011c) propôs um método para seleção de *features* utilizando o algoritmo *Maximum Difference Feature Selection* (MDFS). O método faz a seleção apenas das características essenciais para descrição da textura da mama e elimina todas as *features* que não são relevantes para o aumento da acurácia. Para cada

feature foi calculado o somatório de todos os valores correspondentes de cada imagem, como mostra as Equações (2.8) e (2.9), onde $S1$ e $S2$ representam as somas para o conjunto de mamografias normais e anormais, respectivamente, N é o número de mamografias total e, A_i e B_i correspondem ao valor da *feature* para uma dada imagem na posição i da base:

$$S1 = \sum_{i=1}^{N} A_i \tag{2.8}$$

$$S2 = \sum_{i=1}^{N} B_i \tag{2.9}$$

Assim, a partir dos somatórios, o critério de avaliação da relevância da *feature* é feita seguindo o Algoritmo 1.

Algoritmo 1: Algoritmo para o cálculo da diferença entre *features*

Entrada: *Features* das mamas normais ($A[18][N]$) e anormais ($B[18][N]$)
Saída: Vetor $D[18]$ contendo as Diferença das *features* em ordem decrescente

```
1  para i ← 0 to 17 faça
2  |   para j ← 0 to (N − 1) faça          // N=50 (número de mamografias)
3  |   |   S1+ = A[i][j];
4  |   |   S2+ = B[i][j];
5  |   fim
6  |   se S1 > S2 então
7  |   |   D[i] = (S1 − S2)/(S1 + S2);
8  |   fim
9  |   se S2 > S1 então
10 |   |   D[i] = (S2 − S1)/(S1 + S2);
11 |   fim
12 fim
13 D ← OrdenaVetor(D);
```

As somas e os cálculos das diferenças expressas nas Equações (2.8) e (2.9) são repetidas para todas as 18 *features* extraídas previamente. A partir desses resultados, (NITHYA; SANTHI, 2011c) elaborou uma tabela com os resultados das distâncias em ordem decrescente, onde as cinco primeiras distâncias foram escolhidas para avaliação da relevância das *features*. O algoritmo proposto obteve uma acurácia de 98%, uma sensibilidade de 100% e uma especificidade de 96%.

Em (ELEYAN; DEMİREL, 2011), o cálculo das matrizes de co-ocorrência foi utilizado para reconhecimento de faces. O principal problema inerente aos algoritmos de reconhecimento de faces em tempo real é a complexidade computacional existente na transformação das bases de dados em subespaços para a aplicação dos modelos matemáticos (ELEYAN; DEMİREL, 2011). A confecção do vetor de *features* foi feita de duas

maneiras diferentes: a primeira é baseada nos valores contidos na própria GLCM, ou seja, transformação da matriz quadrada $N \times N$, onde N é o número de níveis de cinza, em um vetor de dimensão $N^2 \times 1$. A segunda confecção utilizou as 14 *features* de Haralick como vetor de *features*.

Para avaliação da performance do algoritmo, foram utilizadas 4 bases de dados de faces: ORL, FERET, FRAV2D and Yale B. Os dois conjuntos de *features* foram testados avaliando as imagens quantizadas em 7 diferentes níveis de cinza (4, 8, 16, 32, 64 e 256). As melhores acurácias para o vetor de *features* da GLCM foi de 72.79% com a base de dados ORL e para o vetor de *features* de Haralick foi de 95.50% também para a mesma base.

Além das imagens de mamografias, os conceitos de matriz de co-ocorrência e extração de *features* de Haralick também são amplamente utilizados em outros estudos envolvendo classificação de imagens médicas. A exemplo disso, em (VIRMANI et al., 2013), a GLCM foi utilizada para a identificação de cirrose em imagens de ultrassom de fígado. A partir de uma base de dados com 31 ultrassons (15 normais e 16 anormais), (VIRMANI et al., 2013) fez a seleção manual das regiões de interesse com o auxílio de um radiologista especialista. As ROIs eram formadas por *bounding boxes*[22] de 32×32 *pixels*, totalizando 120 imagens (60 normais e 60 anormais). A partir dos conceitos de GLCM, foram calculadas dois conjuntos de *features*.

O primeiro vetor, GLCM-*mean*, é composto pelo cálculo da média aritmética entre as quatro *features* f_j^d, onde $j \in \{1, 2, 3, \ldots, 13\}$ descreve as 13 *features* de Haralick utilizadas e $d \in \{1, 2, 3, 4\}$ representando as distâncias descritas previamente. Portanto, o primeiro vetor tem como entradas:

$$GLCM_{MEAN_j} = \frac{f_j^1 + f_j^2 + f_j^3 + f_j^4}{4} = \frac{1}{4} \sum_{d=1}^{4} f_j^d \tag{2.10}$$

O segundo vetor, a GLCM-*range* é composto pelo cálculo da diferença entre o valor máximo de uma *feature* f_j^d e o valor mínimo dessa mesma *feature*, para d variando; portanto teremos:

$$GLCM_{RANGE_j} = \max_{1 \leq d \leq 4} \{f_j^d\} - \min_{1 \leq d \leq 4} \{f_j^d\} \tag{2.11}$$

onde $j \in \{1, 2, 3, \ldots, 13\}$. O melhor resultado, a partir desse experimento, foi para distância fixa $d = 2$ para o vetor GLCM-*range*.

Analisando todos os resultados previamente descritos, (VIRMANI et al., 2013) elaborou um novo experimento, restringindo seu objetivo à seleção de *features*. Utilizando o cálculo da GLCM-*range* com $d = 2$, para todas as 13 *features* de Haralick, foram utilizados 5 algoritmos de seleção de *features*: descriminante de Fisher, distância de Bhattacharyya, divergência, *sequential forward search* (SFS) e *sequential backward search* (SBS).

Para cada algoritmo de seleção, todas as 13 *features* foram testadas e suas respectivas relevâncias foram avaliadas baseadas no nível de acurácia para o problema de

[22] Termo em inglês para a caixa envolvente responsável pela delimitação da região de interesse

classificação das imagens. A Tabela 2.2 mostra as 4 *features* mais relevantes para cada seletor, onde o *Sequential backward selection* obteve o melhor desempenho na classificação das imagens, com uma acurácia de 98.33%.

Tabela 2.2 Seleção das 4 mellhores *features* para classificação de ultrassons de fígado apresentada em (VIRMANI et al., 2013)

Seletor de *Feature*	*Features* selecionadas
Descriminante de Fisher	Contraste Soma dos quadrados (variância) Soma (Entropia) Diferença (Entropia)
Divergência	Contraste Soma dos quadrados (variância) Soma (Entropia) Diferença (Entropia)
Distância de Bhattacharyya	Contraste Soma dos quadrados (variância) Soma (Entropia) Diferença (Entropia)
Sequential forward selection (SFS)	Contraste Soma dos quadrados (variância) Entropia Informação de Medida de Correlação 1
Sequential backward selection (SBS)	Contraste Soma dos quadrados (variância) Diferença do Momento Inverso (IDM) Informação de Medida de Correlação 1

Uma outra abordagem para a classificação de mamografias utilizando matrizes de co-ocorrência é apresentada em (PRATIWI et al., 2015). Desse modo, o trabalho apresenta um estudo comparativo entre duas técnicas de classificação utilizando dois tipos de redes neurais: *Back propagation Neural Network* (BPNN) e *Radial Basis Function Neural Network* (RBFNN). O estudo foi dividido em duas etapas, sendo uma para classificação entre as massas normais e anormais (benignas e malignas) e a outra etapa para classificação de massas anormais, em benignas e malignas. Todas as imagens passaram por um pré-processamento, para a extração da região de interesse de tamanho fixo 128×128 e em seguida, as *features* são extraídas utilizando os conceitos da GLCM, com uma distância $d = 1$ e quatro direções θ, onde $\theta \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$. As *features* escolhidas por (PRATIWI et al., 2015) foram: segundo momento angular (ASM), correlação, soma da entropia, soma da variância.

Ao final do processo de classificação, a validade do método é medida através das métricas de acurácia, especificidade e sensibilidade. Para a classificação de massas normais e anormais, os melhores resultados foram 80.1% e 93.98% para os classifi-

cadores BPNN e RBFNN, respectivamente. Para a classificação das anormalidades (benigna e maligna), os resultados de acurácia apresentaram valores ainda maiores, com 92.1% para BPNN e 94.29% para RBFNN.

2.6 DECOMPOSIÇÃO EM VALORES SINGULARES (SVD)

A decomposição em valores singulares é uma ferramenta poderosa e estável, derivada da álgebra linear (SADEK, 2012a). Essa fatorização é bastante utilizada na área de processamento de sinais digitais (BIGLIERI; YAO, 1989), onde algumas propriedades como a conservação de energia estão sendo utilizadas para compressão de imagens, além da criação de *watermarkers*[23] (SADEK, 2012a).

2.6.1 Definição algébrica

Seja A uma matriz de dimensões $M \times N$, tal que $M \geq N$, onde cada elemento da matriz a_{ij} são reais ou complexos, a SVD da matriz A pode ser representada como mostra a Equação (2.12):

$$A = U_{(M\times M)}\ \Sigma_{(M\times N)}\ V^T_{(N\times N)} \tag{2.12}$$

onde matrizes $U_{(M\times M)}$ e $V_{(N\times N)}$ são matrizes quadradas ortogonais cujos vetores associados à elas são autovetores ortonormais de AA^T e A^TA, respectivamente. Desse modo, as matrizes podem ser definidas nas Equações (2.13) e (2.14):

$$U = \begin{pmatrix} | & & | \\ u_1 & ... & u_M \\ | & & | \end{pmatrix}, \tag{2.13}$$

$$V = \begin{pmatrix} | & & | \\ v_1 & ... & v_N \\ | & & | \end{pmatrix} \tag{2.14}$$

onde $\{u_1, u_2, \ldots, u_M\}$ são as colunas da matriz U e $\{v_1, v_2, \ldots, v_N\}$ são as colunas da matriz V. Essas colunas são chamadas de vetores singulares à esquerda (VSE) e vetores singulares à direita (VSD), respectivamente (SADEK, 2012b).

A matriz Σ é uma matriz diagonal, como pode ser visto na Equação (2.15), onde σ_i é um valor singular de A, com $i \in \{1, 2, 3, \ldots, N\}$ satisfazendo a condição $\sigma_1 \geqslant \sigma_2 \geqslant \sigma_3 \geqslant \sigma_N$:

$$\Sigma = diag(\sigma_1, \sigma_2, \sigma_3, \ldots, \sigma_N) \tag{2.15}$$

A Equação (2.12) pode ser então reescrita como:

$$A = \sum_{i=1}^{R} = u_i\ \sigma_i\ v_i^t \tag{2.16}$$

[23]Termo em inglês para marca d'água em imagens

O valor R, definido como limite da somatória, é representado pelo *rank* da imagem. Partindo do princípio de que A é uma matriz não-singular, temos que $R = N$, ou seja, o *rank* de A é igual ao seu número de colunas (ANDREWS; PATTERSON, 1976). Os valores singulares, representados por σ_i estão associados ao *rank* da matriz A. Pode-se verificar que, o número de valores singulares não-nulos da matriz A representam o *rank* da mesma.

Trazendo para o contexto do processamento digital de sinais, os vetores singulares de U e V^T estão associados com a geometria da imagem representada pela matriz A, enquanto que os valores singulares estão associados a luminância da imagem (SADEK, 2012a).

2.6.2 Aplicações da SVD

Para a classificação de imagens de mamografia, (DANTAS et al., 2011) apresenta um trabalho envolvendo os conceitos de *wavelets* com o objetivo de classificar massas normais e anormais (apenas malignas). Para o desenvolvimento, foram utilizadas 240 imagens da base de dados DDSM (HEATH, 1998), onde 120 eram massas normais e 120 eram massas anormais (malignas), todas com tamanho 128×128 extraídas a partir do *chain code* disponibilizado pela base de dados. A Equação 2.17 apresenta a *wavelet* utilizada para decomposição das ROIs

$$F_{n,m}(a,b) = a^{-m^2} \int x(t)\psi(a^m t - nb)dt \tag{2.17}$$

A partir de duas decomposições de *wavelet*, 8 novas imagens são geradas para cada ROI. A partir das 8 imagens, as imagens de detalhes são selecionadas e utilizadas para a extração de *features*, totalizando 15.360 elementos no vetor de características. O objetivo da utilização da SVD nesse contexto está diretamente ligada à seleção de *features*. Ao final, os resultados apresentaram uma área abaixo da curva ROC igual à 0.83.

Em (VIRMANI et al., 2013) é apresentada uma abordagem para a fatoração em SVD das matrizes de co-ocorrência previamente definidas na Seção 2.5. Como foi descrito, (VIRMANI et al., 2013) dividiu os experimentos em três etapas. A partir da primeira etapa foi possível determinar qual a melhor distância fixa d para o cálculo das GLCMs variando a direção θ, onde $\theta \in \{0°, 45°, 90°, 135°\}$. Portanto, para o último experimento, (VIRMANI et al., 2013) aplicou a decomposição em valores singulares para cada uma das novas matrizes de co-ocorrência, gerando assim quatro matrizes diagonais de valores singulares Σ_j, onde $j \in \{1, 2, 3, 4\}$.

A partir dos valores singulares obtidos através das 4 matrizes de co-ocorrência, uma média aritmética foi calculada para elaboração dos conjuntos de *features*:

$$\sigma_p^n(mean) = \frac{[\sigma_p^n(0°) + \sigma_p^n(45°) + \sigma_p^n(90°) + \sigma_p^n(135°)]}{4} \tag{2.18}$$

onde n varia em $\{1, 2, 3, \ldots, R\}$, p varia em $\{1, 2, 3, \ldots, L\}$, com L sendo o número de ROI's, para d fixo. Nesse caso caso são gerados L vetores do tipo $(\sigma_p^1(mean), \sigma_p^2(mean),$

$\sigma_p^3(mean), \ldots \sigma_p^R(mean))$.

Foram elaborados três conjuntos de *features* derivados dos valores singulares: o primeiro conjunto contendo a média dos dois primeiros valores singulares, o segundo conjunto contendo a média dos três primeiros valores singulares e o último conjunto contendo a média dos quatro primeiros valores singulares.

2.7 ENTROPIA DE TSALLIS

O conceito de entropia está associado as leis da termodinâmica, representando a medida de desordem de um determinado processo (ALBUQUERQUE et al., 2004a). Para o desenvolvimento desse trabalho, algumas medidas estatísticas de entropia foram utilizadas como *features* para compor o vetor para classificação das imagens em massa e não-massa.

2.7.1 Definição algébrica

A entropia de Tsallis é uma generalização da fórmula da entropia de Boltzmann-Gibbs-Shannon. Essa entropia é responsável por calcular a medida de desordem de mameira macroscópica. Por outro lado, a entropia de Boltzmann-Gibbs-Shannon retorna essa medida para um conjunto específico (Tsallis, 1988), como é expressado na Equação (2.19)

$$S = -k \sum_{i=1}^{W} p_i \ln p_i \tag{2.19}$$

onde W é o total de microscópicas possibilidades e p_i é uma possibilidade específica.

A partir da generalização da Equação (2.19), Tsallis (Tsallis, 1988) generalizou a fórmula da entropia através da Equação (2.20). Desse modo, quando o $q \to 1$, tem-se a Entropia de Boltzmann-Gibbs-Shannon.

$$S = \frac{1}{(q-1)}(1 - \sum_{i=1}^{N} p_i^q) \tag{2.20}$$

onde N é o número de eventos.

2.7.2 Aplicações da Entropia de Tsallis

Por ser uma generalização da fórmula da entropia de Boltzmann-Gibbs-Shannon, a Entropia de Tsallis é utilizada em diversos áreas de estudo. Para as aplicações na área de processamento de imagens, essa entropia é amplamente utilizada para a segmentação de imagens.

Em (ALBUQUERQUE et al., 2004b) um método para segmentação de imagens é apresentado baseado na Entropia de Tsallis. Quando o valor de S (vide Equação 2.20) é máximo, encontra-se o melhor valor de *threshold*. Além dos processos de segmentação, a Entropia de Tsallis é utilizada para detecção de objetos na imagem, através do melhoramento delas. A exemplo dessas aplicações, (MOHANALIN et al., 2010)

apresenta uma nova metodologia para detecção de microcalcificações utilizando as propriedades da Entropia de Tsallis, com o objetivo de encontrar o melhor valor para o índice q para esse problema. Os experimentos foram elaborados utilizando 247 imagens e o índice de classificação foi de 93.55%.

2.8 FUNDAMENTOS DO RECONHECIMENTO DE PADRÃO

O reconhecimento de objetos, ou padrões, pode ser definido como os processos de pesquisar e encontrar um conjunto de *pixels* que consiga representar, de maneira correta, um determinado objeto, previamente definido, e em seguida, classificar o objeto através de uma *label* (PARKER, 2010).

Um padrão pode ser definido como sendo um arranjo de descritores (GONZALEZ; WOODS, 2002). Esses descritores, também conhecidos como *features* podem ser agrupados em forma de vetor, de *strings* e em forma de árvores. Os vetores de *features* podem ser descritos como:

$$\mathbf{x} = [x_1 \;\; x_2 \;\; x_3 \;\; \ldots \;\; x_n]^T \tag{2.21}$$

onde cada componente do vetor x_i é um descritor e então n representará o número total de descritores para um determinado padrão. Uma classe de padrões será então definida como sendo um conjunto de padrões que possuem propriedades comuns e são representadas por: $\omega_1, \omega_2, \omega_3, \ldots, \omega_W$, sendo que W será o número total de classes. Portanto, o objetivo das técnicas de reconhecimento de padrões é atribuir um padrão à uma determinada classe a partir da avaliação de seus descritores com um mínimo possível de intervenção humana (GONZALEZ; WOODS, 2002).

A abordagem do reconhecimento de padrão pode ser dividida em duas categorias: a decisão teórica e a decisão estrutural. Na primeira, o método utilizará descritores quantitativos (área, textura e comprimento) para fazer o reconhecimento de um determinado objeto. Na segunda, os descritores devem ser qualitativos (GONZALEZ; WOODS, 2002).

Os métodos de aprendizagem supervisionados englobam os algoritmos de criação de vetores de informação extraídos a partir da base de treinamento e desenvolvem o processo de *matching* com os vetores da base de teste. Métodos nos quais os vetores de entrada da base de treinamento não fazem correspondência com um vetor de base de teste são chamados de métodos de aprendizagem não supervisionados. Para esses problemas, o objetivo é encontrar uma similaridade entre grupos no processo de *clustering* (BISHOP, 2006).

Segundo (HARALICK; SHANMUGAM; DINSTEIN, 1973), a grande dificuldade em classificar uma imagem é encontrar um conjunto de *features* que consiga expressar todas as suas características. Portanto, quando o conjunto é definido, a aplicação de técnicas de reconhecimento de padrões pode ser feita.

Uma sequência de passos pode ser definida para o processo de reconhecimento de um objeto em uma cena (PARKER, 2010):

1. Escolher o objeto que deve ser encontrado na cena;

2. Utilizar algum algoritmo de processamento de imagens para isolar o objeto dos demais objetos presentes na cena;

3. Utilizar a segmentação de imagens para fazer o recorte desse objeto;

4. Avaliar e definir uma *feature* que consiga representar de maneira estatística o objeto;

5. Verificar o desempenho da *feature* no processo de reconhecimento do objeto. Se ela não for suficiente, deve-se escolher outra *feature* e repetir esse passo até que se encontre a medida mais adequada para representar as características do objeto;

Uma determinada imagem ou objeto na imagem podem ser identificados por mais de uma *feature*. Ou seja, é possível a criação de um conjunto de *features* com o objetivo de aprimorar a aplicação dos algoritmos de reconhecimento de padrões.

Para a classificação de uma imagem é necessário definir, primordialmente, um conjunto de imagens semelhantes (imagens que contenham características iguais) para a fase de treinamento. Um algoritmo de reconhecimento de padrão consegue definir intervalos para cada *feature* e a partir disso encontrar padrões que definam uma imagem. Portanto, quanto maior o número de imagens semelhantes, ou seja o conjunto de treinamento, mais eficaz será o aprendizado do algoritmo e, consequentemente, ele poderá identificar de maneira mais precisa àquela imagem ou àquele objeto na cena na fase de teste.

2.8.1 Extração de características

Um conjunto de *features* pode ser definido como um conjunto de medidas que são extraídas de uma determinada imagem. Inicialmente, o objetivo principal do reconhecimento de padrões é então, conseguir isolar as regiões de interesse da imagem, fazer a extração do conjunto de *features* e posteriormente identificar a imagem a partir dessas características (PARKER, 2010).

O principal objetivo da extração das *features* é conseguir representar uma imagem através de uma pequena quantidade de informações, tornando o processo de decisão dos algoritmos de classificação mais simples e com o baixo custo computacional (NITHYA; SANTHI, 2011b).

Um estudo comparativo entre alguns métodos de extração de *features* foi proposto em (NITHYA; SANTHI, 2011b). Utilizando 250 imagens da base de dados DDSM, onde 125 eram mamografias normais e 125 eram anormais, foram aplicados três métodos de extração: *features* de intensidade a partir do histograma das imagens, *features* de Haralick a partir da GLCM das imagens e *features* baseadas na intensidade. A Tabela 2.3 apresenta todas as *features* utilizadas por cada um dos métodos para classificação das imagens de mamografia.

Para a etapa de classificação, (NITHYA; SANTHI, 2011b) utilizou uma rede neural de três camadas. Para o método de intensidade de histograma, a acurácia foi de 92%, para o método da GLCM foi de 98% e para o método de intensidade da imagem

Tabela 2.3 *Features* utilizadas em cada método de extração (**??**)

Método de Extração de *Features*	***Features* selecionadas**
Features da Intensidade de Histograma	*Smoothness* Uniformidade Terceiro Momento Entropia
Features de Haralick	Contraste *Cluster Shade* Energia Soma dos quadrados (variância)
Features de Intensidade	Média Moda Variância Desvio Padrão

foi de 96%. Portanto, a classificação de mamografias utilizando as matrizes de co-ocorrências e as *features* de Haralick (HARALICK; SHANMUGAM; DINSTEIN, 1973) se mostraram bastante adequadas.

2.8.2 Classificadores

O processo de reconhecimento de objetos é composto de duas etapas. A primeira etapa é a montagem da base de dados para a descoberta de regularidades, ou seja, características comuns que consigam representar aquele objeto. A segunda etapa é utilizar um algoritmo de classificação, conhecido como classificador, para identificar outros objetos através das características extraídas da base de dados de aprendizagem.

2.8.2.1 Support Vector Machine (SVM) A metodologia aplicada às máquinas de vetores de suporte (SVM) é semelhante ao conceito de um discriminante linear. É possível, através da análise de uma *feature*, traçar uma linha entre um conjunto de amostras, separando essas amostras em duas classes diferentes, como pode ser visto na Figura 2.10. Com um maior número de *features*, o discriminante passa a ser limitado por um plano ou hiperplano (PARKER, 2010). O objetivo é então, escolher qual a melhor linha ou hiperplano que separa um conjunto de amostras em duas classes. Ou seja, o discriminante que alcança a maior margem para a separação das amostras.

A SVM é uma máquina de decisão e portanto não está habilitada a retornar nenhuma probabilidade (BISHOP, 2006).

A classificação utilizando SVM é feita apenas para duas classes ou, se houver mais de duas classes, o SVM classificará através de uma alocação entre pares de classes (PARKER, 2010). O problema de classificação de duas classes distintas é representado pelo modelo linear descrito na Equação (2.22):

$$y(x) = w^T \varphi(x) + b \tag{2.22}$$

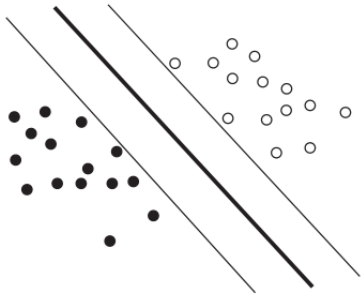

Figura 2.10 Representação de um descriminante linear ótimo
Fonte: (PARKER, 2010)

onde a função $\varphi(x)$ representa uma transformação fixa de espaço de *feature*. O conjunto de treinamento pode ser definido por $x_1, x_2, x_3, \ldots, x_N$, onde N é o número de vetores de entrada e seus vetores alvos correspondentes $t_1, t_2, t_3, \ldots, t_N$, onde $t_N \in \{-1, +1\}$. Partindo do fato de que a função de separabilidade das classes é linear, o objetivo então é encontrar valores para w e b, tal que $y(x_n) > 0$ para todos os pontos onde $t_N = +1$ e $y(x_n) < 0$ para todos os pontos onde $t_N = -1$.

Ou seja, um determinado objeto pode ser descrito como um conjunto de valores, denominados de *features* e uma *label*, representando a classe na qual esse objeto está inserido. Os conjuntos de treinamento e teste contêm uma determinada quantidade de objetos, organizados como foi descrito anteriormente.

O objetivo principal da SVM é então, a partir da análise dos valores de *features* presentes nesse conjunto de treinamento, determinar um modelo para que seja possível a classificação do conjunto de teste sem o conhecimento da *label* de cada objeto (CHANG; LIN, 2011).

A solução encontrada deve retornar o menor erro de generalização. Por isso, deve-se obter a menor distância entre a borda de decisão e as amostras dos vetores de entrada. Esse resultado representa a maximização da margem que separa as amostras em duas classes distintas.

Capítulo 3

Este capítulo descreve todas as etapas elaboradas para o desenvolvimento desse trabalho. Serão abordadas as principais características da base de dados utilizada, as metodologias de pré-processamento, baseadas nos conceitos do processamento de imagem digital, os modelos matemáticos escolhidos para o processo de classificação e as métricas estatísticas utilizadas para a avaliação desses modelos

METODOLOGIA

O desenvolvimento desse trabalho foi baseado em um conjunto de etapas envolvendo desde a aquisição das imagens na base de dados e o seu pré-processamento até o desenvolvimento dos modelos matemáticos e aplicação das técnicas de reconhecimento de padrões para a classificação dos resultados obtidos através da extração de características dessas imagens. A Figura 3.1 apresenta um fluxograma que descreve, de maneira sequencial, todas as etapas elaboradas nesse trabalho.

Figura 3.1 Fluxograma simplificado da metodologia do trabalho

3.1 FERRAMENTAS

Para o desenvolvimento desse projeto foram utilizadas algumas ferramentas com o objetivo de auxiliar na implementação das funções.

Todas as etapas de implementação foram desenvolvidas nas linguagens C/C++, utilizando o *framework* Qt Creator (NOKIA, 2015) e todo o suporte oferecido para a criação de interface UI. Além disso, contamos com o auxílio das bibliotecas OpenCV, libSVM (CHANG; LIN, 2011) e Armadillo C++ (SANDERSON, 2010).

O Qt-Creator (NOKIA, 2015) é uma ferramenta multiplataforma e um *framework* para desenvolvimento de interface UI. Por ser uma ferramenta *open source* e pelo suporte à implementações de interfaces, esse framework foi escolhido para criação de uma interface para manipulação das imagens e arquivos utilizados nesse trabalho.

A biblioteca OpenCV oferece suporte às linguagens C, C++, Python e Java, além de ser *cross-plataform*. Essa biblioteca foi desenvolvida com o objetivo de auxiliar na implementação de procedimentos da área da Computação Visual.

A biblioteca Armadillo C++ (SANDERSON, 2010) foi utilizada para o cálculo da decomposição em valores singulares. Essa biblioteca apresenta um conjunto de funções estáveis para o desenvolvimento de operações algébricas e por esse motivo foi escolhida para a implementação dos métodos envolvendo valores e vetores singulares.

Para a etapa final (classificação) foi utilizada a biblioteca LibSVM (CHANG; LIN, 2011). Essa biblioteca, desenvolvida desde 2000, oferece suporte à implementação de métodos de classificação derivados da *Support Vector Machine*, além de proporcionar algumas características favoráveis como a utilização de classificação *multi-class*, seleção manual de parâmetros para o melhoramento do processo de classificação e a implementação de métodos que retornam as respectivas probabilidades.

A biblioteca apresenta a definição de classes distintas e que auxiliam a implementação dos conceitos da SVM, como por exemplo a definição do problema (*svm-problem*), a definição dos *nodes* (*svm-node*) que irão compor esse problema (também conhecidos como *features*) e criação de parâmetros de ajuste da função linear para a classificação (*svm-parameter*), que envolve os valores de γ e de C.

3.2 AQUISIÇÃO DAS IMAGENS

O processo de aquisição de imagens compõe um dos fundamentos do processamento de imagens. O progresso do método desenvolvido está diretamente ligado ao resultado obtido nessa etapa.

3.2.1 Digital Database Screening Mammography (DDSM)

O objetivo desse trabalho envolve a implementação de modelos matemáticos para auxiliar na classificação de massas em mamografias. A base de dados escolhida foi a *Digital Database Screening Mammography* (DDSM) (HEATH, 1998). Essa base foi criada como um projeto colaborativo entre o *Breast Cancer Research Program of the U.S. Army Medical Research and Materiel Command*, *Massachusetts General Hospital*, *University of South Florida* e *Sandia National Laboratories*, com o objetivo de forncecer uma base de dados completa e consistente, para pesquisas que envolvem o desenvolvimento de ferramentas de melhoramento dos exames de mamografias e ferramentas que implementam algoritmos para a detecção (CADe) e o diagnóstico de massas (CADx), nesse tipo de imagem.

As imagens contidas na base foram avaliadas por vários radiologistas especialistas para obtenção de um laudo médico coerente para cada paciente. Para isso, todas as imagens de mamografia passaram por um processo de coleta de informações consideradas relevantes para o aprimoramento das técnicas computacionais de processamento de imagens e reconhecimento de padrões. Essas informações foram catalogadas através de 16 categorias que descrevem desde o tipo de filme utilizado para impressão

do exame, até o tipo de lesão apresentada nas mamografias (caso exista a presença do nódulo, para os casos de exames anormais). Todas as informações foram arquivadas em arquivos de texto, que estão descritos na Seção 3.2.1.1.

3.2.1.1 Organização da base de dados A organização da base foi elaborada através de casos, onde cada um deles representa um paciente. Para manter o sigilo total desse individuo, não estão descritas na base informações pessoais, tais como nome, endereço e número de documentos que possam identificar o paciente.

Ao total a base de dados contém 2620 diferentes casos, divididos em 695 casos normais, 870 casos benignos, 141 casos benignos mas sem retorno do paciente e 914 casos malignos. Em cada caso, estão contidas 4 imagens de mamografias, com duas diferentes visões da mama: visão médio lateral-oblíqua das mamas esquerda e direita, e visão crânio-caudal das mamas esquerda e direita.

Tabela 3.1 Tabela de categorias presentes no arquivo ***.ics***

Nome da categoria	Significado
filename	Nome do caso de estudo
DATE_OF_STUDY	Data na qual o estudo foi fetio
PATIENT_AGE	Idade do paciente do caso
FILM_TYPE	Tipo de filme utilizado para imprimir o exame de mamografia
DENSITY	Densidade do filme
DATE_DIGITIZED	Data da digitalização das imagens
DIGITIZER	Tipo de *scanner* utilizado para as digitalizações
SELECTED	Lista de arquivos selecionados para compor a pasta do caso

Além das mamografias, para cada caso, existe um arquivo texto, com extensão ***.ics***. Para os casos que contém a presença de uma massa suspeita, existe ainda, quatro arquivos texto com extensão ***.overlay***, cada um relacionado com uma imagem. As Tabelas 3.1 e 3.2 apresentam todas as categorias contidas nos arquivos ***.ics*** e ***.overlay***, respectivamente.

Tabela 3.2 Tabela de categorias presentes no arquivo ***.overlay***

Nome da categoria	Significado
TOTAL_ABNORMALITIES	Total de anormalidades encontradas
ABNORMALITY	Grau de anormalidade
LESION_TYPE	Tipo de lesão encontrada
PATHOLOGY	Descreve a patologia do nódulo (benigna ou maligna)
TOTAL_OUTLINES	Total de nódulos
BOUNDARY	Descreve a lista de *chain codes* para cada nódulo

O *chain code* apresentado nos arquivos de texto ***.overlay*** são utilizados para descrever as bordas das anormalidades presentes na imagem de mamografia, identificados pela palavra *BOUNDARY*. Em alguns casos, existem mais de uma anormalidade, portanto, são descritos mais de um *chain code* em um mesmo arquivo, identificados pela palavra *CORE*. Dessa forma, em uma mamografia que contenha mais de uma anormalidade, existirão os *chain codes* de cada anormalidade e um *chain code* delimitando toda a área de anormalidades. Na Figura 3.2 é apresentado um exemplo de *chain code* da DDSM (HEATH, 1998). Os dois primeiros valores correspondem a coordenada (x, y) do *pixel* inicial e final, tendo em vista que o *chain code* começa e inicia no mesmo ponto. Os valores subsequentes correspondem as próximas orientações para delimitação dos demais *pixels* da borda do nódulo.

```
BOUNDARY
1897 3158 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6
6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 4 4 4 4 4 4 4 6 6 6 6
4 4 4 4 4 4 4 4 6 6 6 6 6 6 6 6 5 5 5 5 5 5 5 6 6 6 6 6 6 6 6 6 6 6
6 6 6 6 6 4 4 4 4 4 4 4 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6
6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 6 7 7 7 7 7 7 7 6 6 6 6 6 6
```

Figura 3.2 Exemplo de *chain code* apresentado na DDSM
Fonte: (HEATH, 1998)

3.3 PRÉ-PROCESSAMENTO

A etapa de pré-processamento das imagens extraídas consiste apenas na equalização das ROIs utilizando o algoritmo de equalização de histograma.

3.3.1 Extração de ROIs

A partir das informações obtidas através dos arquivos de texto provenientes da base de dados DDSM (HEATH, 1998), foram utilizados para extração das ROIs correspondentes às imagens anormais (contendo uma região de nódulo). Inicialmente, a partir da leitura do *chain code* é possível calcular os pontos de alturas mínima e máxima, e larguras mínima e máxima do nódulo de uma imagem. A partir desses valores foi possível calcular um valor para o *pixel* central para inicialização da extração. A leitura do *chain code* é baseada nos conceitos fundamentais do processamento de imagens digital. Sendo (x, y) as coordenadas de um *pixel* inicial, o algoritmo faz a leitura do arquivo ***.overlay*** e, baseado na configuração de 8 direções do *chain code* da DDSM (Figura 2.8), é possível determinar qual o próximo valor do *pixel* da borda.

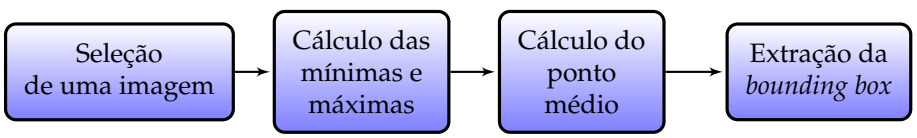

Figura 3.3 Fluxograma simplificado da etapa de aquisição das imagens

Inicialmente, é feita a leitura do texto ***.overlay***, mais precisamente a linha que contém o *chain code* que representa a borda do nódulo é armazenada em um vetor de inteiros (*vetorchain*), onde nas duas primeiras posições desse vetor estão armazenadas a coordenada (x, y) inicial e a leitura termina quando o algoritmo encontra o caractere **#** que delimita o fim da cadeia. Na próxima etapa, o algoritmo faz a leitura desse vetor, partindo do ponto inicial do *chain code* e salvando as coordenadas horizontais e verticais de cada novo *pixel* em dois vetores: *vetorcoordx* e *vetorcoordy*. A Figura 3.3 descreve o processo de aquisição das regiões de interesse.

A próxima etapa envolve a determinação das coordenadas mínimas e máximas para delimitar o tamanho da *bounding box* da massa. O algoritmo faz a leitura do *vetorcoordx* e *vetorcoordy*, e faz um comparativo entre os valores horizontais e verticais, encontrando os valores máximos e mínimos para x e y. Após a determinação desses *pixels*, a última etapa consiste na extração da *bounding box*. Foram extraídos blocos de tamanho 64×64. O algoritmo utiliza o conceito de ponto médio para calcular um valor de coordenada (x, y) do *pixel*, que representa o ponto no centro da *bounding box* previamente delimitada.

A partir desse ponto central, são extraídas as ROIs com os tamanhos descritos acima. Portanto, para cada imagem de mamografia anormal é extraída apenas uma ROI, e esta possuirá o mesmo ponto central calculado previamente (ver Figura 3.4). Pela forma do nódulo, em alguns casos, a partir do cálculo do *pixel* central, a delimitação da ROI pode englobar parte do tecido mamário sadio, o que pode comprometer o resultado, no momento da classificação. Por isso, para que a base seja composta de dados consistentes, após a extração de todas as regiões, foi feita uma análise manual, para verificar se as *bounding boxes* extraídas pertenciam somente à região suspeita. Em caso negativo, a mamografia era excluída da base. Ao total, foram extraídas apenas quatro imagens nas quais o método não retornou uma ROI pertecente ao limite do *chain code*, de um total de 1.937 imagens.

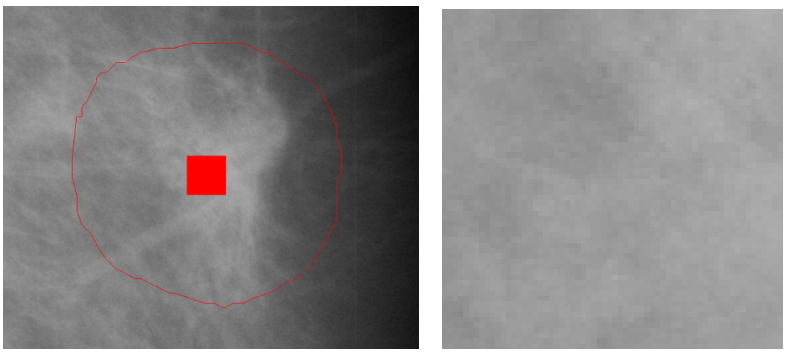

(a) (b)

Figura 3.4 (a) Exemplo de uma ROI e *chain code* do nódulo delimitada (b) ROI extraída a partir da *bounding box*

Para as massas normais, as ROIs foram extraídas apenas selecionando uma região central da mama, para que não houvesse nenhum artefato prejudicial à aplicação dos

métodos de classificação, como por exemplo regiões de massa muscular ou de *background* do próprio exame de mamografia. No total, foram utilizadas 294 imagens de não-massa e 294 imagens de massas, onde foram selecionadas de maneira aleatória a quantidade de imagens benignas e malignas.

3.4 EQUALIZAÇÃO DA BASE

Após a etapa de extração de todas as ROIs a partir das mamografias da DDSM (HEATH, 1998), é necessário aplicar uma técnica para realce dos *pixels* da imagem para aprimoramento das técnicas de extração de *features*. A Equalização de Histograma é feita a partir do cálculo do histograma de cada ROI. Todas as imagens são de 8-bits, ou seja, possuem 256 níveis de cinza, consequentemente o histograma da imagem varia entre os níveis de cinza 0 e 255. A técnica desenvolvida nessa etapa foi baseada nos conceitos apresentados na Seção 2.4.2 através do cálculo das probabilidades de cada nível de cinza, como mostrou a Equação (2.5).

A Figura 3.5 apresenta um fluxograma resumido das etapas de equalização das ROIs.

Figura 3.5 Fluxograma simplificado da etapa de equalização

3.5 EXTRAÇÃO DE *FEATURES* DAS ROIS

Nesta seção serão descritos todos os experimentos aplicados à base de dados para elaboração de um estudo comparativo entre técnicas de extração de *features* a partir da matriz de co-ocorrência e técnicas de extração de *features* a partir da decomposição em valores singulares. No Capítulo 4 serão apresentados todos os resultados desses comparativos.

3.5.1 Matriz de Co-ocorrência das ROIs

Matrizes de co-ocorrência foram criadas para cada ROI equalizada, seguindo quatro direções e quatro distâncias. Nesse caso, $\theta \in \{0°, 45°, 90°, 135°\}$ e $d \in \{1, 2, 3, 4\}$, conforme é descrito na Seção 2.5.

Segundo (HARALICK; SHANMUGAM; DINSTEIN, 1973), após a criação das matrizes de co-ocorrência, é necessário fazer cálculo da matriz normalizada, para que todos os valores da GLCM pertençam ao mesmo intervalo. A matriz normalizada é obtida através da divisão de cada entrada da matriz de co-ocorrência $P(i, j)$ pela soma de todos as entradas da matriz de co-ocorrência. Portanto, uma nova função foi implementada para o cálculo da normalização, que recebe como parâmetro a matriz de co-ocorrência e retorna a matriz normalizada correspondente.

Nas próximas seções serão apresentados todos os experimentos desenvolvidos nesse trabalho envolvendo os conceitos de matriz de co-ocorrência, decomposição em valores singulares e entropia de Tsallis, descritos previamente no Capítulo 2.

3.6 EXPERIMENTOS COM A GLCM DA IMAGEM

Para cada ROI, são calculados seis níveis de quantização uniforme $(2^3, 2^4, 2^5, 2^6, 2^7, 2^8)$ e para cada um dos níveis, são calculadas as matrizes de co-ocorrência (com direção ou distância fixa), em seguida as matrizes são normalizadas para extração das *features* baseadas na Entropia de Tsallis apresentada na Seção 2.7.

3.6.1 Experimento I sob direções fixas

Para o primeiro experimento, foram utilizados os conceitos do cálculo da matriz de co-ocorrência (GLCM) derivados de uma imagem em tons de cinza para uma direção fixa θ, onde $\theta \in \{0°, 45°, 90°, 135°\}$, variando a distância d em quatro valores ($d \in \{1, 2, 3, 4\}$). O algoritmo 2 apresenta o desenvolvimento desse experimento.

Algoritmo 2: Primeiro experimento

Entrada: imagem, θ fixo, q fixo
Saída: vetor de *features* da imagem

```
1 para d ← 1 to 4 faça
2     para k ← 3 to 8 faça
          // Cálculo da GLCM normalizada
3         M_{d,k} ← matrizHaralick (d, θ, imagem);
          // Extração dos vetores de features
4         f_{d,k} ← extraiFeaturesTsallis (M_{d,k});
5     fim
6 fim
7 vetor_final = (f_{1,3}, ..., f_{1,8}; ...; f_{4,3}, ..., f_{4,8});
8 classifica (vetor_final);
```

De acordo com os conceitos apresentados na Seção 2.7, o valor do índice q é estabelecido a partir do desempenho do experimento em questão. Dessa forma, esse experimento foi dividido em três etapas, fazendo a variação dos intervalos de q, com o objetivo de encontrar um valor que seja adequado para o processo de classificação de massas e não-massas.

Para a primeira etapa, foi delimitado o intervalo $[0.1, 0.9]$, com incrementos de 0.1, totalizando nove valores diferentes para o índice q. Na segunda etapa, um novo intervalo $[1.1, 1.9]$ foi delimitado, também com variância de 0.1 entre cada um dos valores.

3.6.2 Experimento II sob distâncias fixas

No segundo experimento, o conceito de GLCM foi utilizado fixando uma distância d e variando a direção em quatro ângulos diferentes ($\theta \in \{0°, 45°, 90°, 135°, \}$). O algoritmo 3 apresenta o desenvolvimento desse experimento.

Algoritmo 3: Segundo experimento

Entrada: imagem, d fixo, q fixo
Saída: vetor de *features* da imagem

para $\theta \leftarrow 0°$ **to** $135°$ *de* $45°$ *em* $45°$ **faça**
  para $k \leftarrow 3$ **to** 8 **faça**
    `// Cálculo da GLCM normalizada`
    $M_{\theta,k} \leftarrow$ `matrizHaralick` $(\theta, \theta,$ imagem$)$;
    `// Extração dos vetores de features`
    $f_{\theta,k} \leftarrow$ `extraiFeaturesTsallis` $(M_{\theta,k})$;
  fim
fim
vetor_final $= (f_{(0°,3)}, \ldots, f_{(0°,8)}; \ldots; f_{(135°,3)} \cup f_{(135°,8)})$;
`classifica` (vetor_final);

3.7 EXPERIMENTOS COM A SVD DA GLCM DA IMAGEM

Para cada ROI, são calculados seis níveis de quantização $(2^3, 2^4, 2^5, 2^6, 2^7, 2^8)$ e para cada um dos níveis, são calculadas as matrizes de co-ocorrência (com direção ou distância fixa), em seguida as matrizes são normalizadas. A partir dessas matrizes quadradas, são calculadas as matrizes de valores singulares (SVD) para extração das *features* baseadas na Entropia de Tsallis apresentada na Seção 2.7.

3.7.1 Experimento I sob direções fixas

O terceiro experimento foi desenvolvido a partir dos conceitos de valores singulares e matriz de co-ocorrência da imagem. Inicialmente, uma ROI de uma imagem da base de dados é quantizada em seis níveis de cinza $(2^3, 2^4, 2^5, 2^6, 2^7$ e $2^8)$. Para cada uma dessas novas imagens, uma matriz de co-ocorrência é calculada e sua correspondente normalizada. A partir dessas últimas matrizes normalizadas e quadradas, são calculadas as matrizes de valores singulares (SVD).

Por fim, os valores singulares são então utilizados para o cálculo da Entropia de Tsallis de cada imagem. O processo é repetido para cada distância d, onde $d \in \{1, 2, 3, 4\}$. Dessa forma, teremos um total de 24 matrizes de SVD diferentes. O algoritmo 4 apresenta de forma simplificada o processo de obtenção dessas *features*.

3.7.2 Experimento II sob distâncias fixas

O último experimento desenvolvido nesse projeto foi o cálculo da entropia de Tsallis baseado nos conceitos de SVD da matriz de co-ocorrência utilizando uma distância d fixa ($d \in \{1, 2, 3, 4\}$) e variando a direção θ ($\theta \in \{0°, 45°, 90°, 135°\}$), como pode ser visualizado no Algoritmo 5.

Algoritmo 4: Terceiro experimento

Entrada: imagem, θ fixo, q fixo
Saída: Vetor de *features* da imagem

para $d \leftarrow 1$ **to** 4 **faça**
  para $k \leftarrow 3$ **to** 8 **faça**
    `// Cálculo da GLCM normalizada`
    $M_{d,k} \leftarrow$ `matrizHaralick` (d, θ, imagem);
    `// Cálculo da SVD a partir GLCM normalizada`
    $S_{d,k} \leftarrow$ `calculaSVD` ($M_{d,k}$);
    `// Extração dos vetores de features;`
    $f_{d,k} \leftarrow$ `extraiFeaturesTsallis` ($S_{d,k}$);
  fim
fim
vetorFinal = $(f_{(1,3)}, \ldots, f_{(1,8)}; \ldots; f_{(4,3)}, \ldots, f_{(4,8)})$;
`classifica` (vetorFinal);

3.8 CLASSIFICAÇÃO DAS FEATURES

Após a criação de cada vetor de *features*, passa-se a determinação dos arquivos de treinamento e teste para a classificação das ROIs das imagens. O algoritmo desenvolvido nessa etapa, recebe como parâmetro dois arquivos texto (**.txt**) contendo os caminhos para todas as imagens de massas e não massas de dimensão 64×64. A partir disso, é feita uma leitura de cada linha dos arquivos, para que elas possam ser armazenadas em dois vetores distintos (vetor para o arquivo **não massa** e um vetor para o arquivo **massa**) para que possa ser feita a escolha aleatória das imagens.

A partir desses dois vetores, serão montados quatro arquivos (treinamento e teste para não massas e, treinamento e teste para massas). Para essa etapa, gera-se um número aleatório e verifica-se se ele é par ou ímpar. Caso seja par, gera-se um novo número aleatório (dentro do intervalo do tamanho do vetor de não massas) para escolher uma posição do vetor que corresponderá à uma imagem e dessa maneira escreve-se essa imagem em um arquivo texto: **arquivo_normal_train.txt**. Se o número for ímpar, repete-se o mesmo processo para o vetor de massas e arquiva-se cada nova imagem escolhida em um outro arquivo texto: **arquivo_abnormal_train.txt**. Esse processo é repetido até que se atinja o número de amostras para a fase de treinamento (100 amostras, onde 50 são de não massas e 50 são de massas).

Para o arquivo de teste fazemos exatamente o mesmo processo descrito anteriormente, exceto pelo tamanho do arquivo, que nesse caso será igual à 594 (onde 297 são de não massa e 297 são de massa). Ao final desse processo, têm-se quatro arquivos texto contendo as amostras de não massa, de treinamento e teste e as amostras de massa, também de treinamento e teste. Para garantir que uma mesma amostra seja selecionada duas vezes, a cada escolha aleatória, a imagem é deletada do vetor.

Uma nova função foi implementada para fazer a junção entre os arquivos par a

Algoritmo 5: Quarto experimento

Entrada: Imagem da base, distância d, q
Saída: Vetor de *features* representando imagem

para $\theta \leftarrow 0°$ **to** $135°$ *de* $45°$ *em* $45°$ **faça**
  para $k \leftarrow 3$ **to** 8 **faça**
    `// Cálculo da GLCM normalizada`
    $M_{\theta,k} \leftarrow$ `matrizHaralick` (d, θ, imagem);
    `// Cálculo da SVD a partir GLCM normalizada`
    $S_{\theta,k} \leftarrow$ `calculaSVD` ($M_{\theta,k}$);
    `// Extração dos vetores de features;`
    $f_{\theta,k} \leftarrow$ `extraiFeaturesTsallis` ($S_{\theta,k}$);
  fim
fim
vetor_final = $(f_{(0°,3)}, \ldots, f_{(0°,8)}; \ldots; f_{(135°,3)}, \ldots, f_{(135°,8)})$;
`classifica` (vetor_final);

par. Essa função também escolhe as amostras de maneira aleatória e portanto, ao final temos apenas dois novos arquivos: **arquivo_train.txt** e **arquivo_teste.txt**, que serão utilizados pelo classificador.

Ao final do processo de treinamento e teste, um arquivo texto chamado **debug.txt** é criado contendo as predições elaboradas pelo classificador a partir do conjunto de features utilizadas e das imagens aleatoriamente selecionadas. A partir desse arquivo, pode-se calcular as medidas estatísticas (Seção 3.9) necessárias para avaliação dos métodos desenvolvidos nesse trabalho. Esse processo é desenvolvido a partir de uma comparação entre o arquivo de predição (**debug.txt**) e o arquivo original de teste **arquivo_teste.txt**, onde cada linha é avaliada e a similaridade entre elas é avaliada.

Para cada execução do algoritmo, utilizamos o *script* em *pyhton* da libSVM (CHANG; LIN, 2011) para avaliar quais os melhores parâmetros γ e C para que aquele teste atinja os melhores resultados de acurácia.

3.9 METODOLOGIA DE AVALIAÇÃO

Para validação e comparação dos experimentos cinco medidas estatísticas são calculadas a partir dos resultados obtidos através do processo de classificação descrito na Seção 3.8. O algoritmo faz um comparativo entre os valores descritos no arquivo *predict* e nas *labels* descritas no arquivo de teste. A comparação é feita linha à linha e um vetor é criado para salvar os resultados dessa comparação.

Para cada comparação, são avaliados se o resultado é verdadeiro-positivo (*true-positive*) (TP), falso-positivo (*false-positive*) (FP), verdadeiro-negativo (*true-negative*) (TN) e falso-negativo (*false-negative*) (FN), de acordo com a Tabela 3.3.

Um vetor de quatro posições foi criado para armazenar os resultados desse comparativo. A cada leitura de uma linha o comparativo é feito, e a posição do vetor cor-

Tabela 3.3 Calculo das estatísticas através das *labels*

Resultado	Arquivo *predict*	Arquivo teste
Verdadeiro-Positivo (TP)	-1	-1
Falso-Positivo (FP)	-1	1
Verdadeiro-Negativo (TN)	1	1
Falso-Negativo (FN)	1	-1

respondente aquele resultado é incrementado. Ao final, as medidas estatísticas serão extraídas a partir desse vetor. Para esse trabalho, as cinco medidas estatísticas utilizadas foram acurácia, sensibilidade, especificidade, valor preditivo positivo (VPP) e valor preditivo negativo (VPN).

3.9.1 Acurácia

A acurácia é uma das medidas estatísticas mais utilizadas para avaliar um sistema CAD/CADx. Essa métrica representa a porcentagem de diagnósticos corretos identificados pelo classificador.

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FN + FP} \tag{3.1}$$

3.9.2 Sensibilidade

Essa métrica é responsável por avaliar a porcentagem de ROIs anormais corretamente identificadas pelo classificador. A Equação (3.2) descreve esse cálculo (SAMPAT; MARKEY; BOVIK, 2005).

$$\begin{aligned} Sensibilidade &= \frac{\text{Total de Verdadeiro-Positivo (TN)}}{\text{Número de ROIs anormais}} \\ &= \frac{TP}{TP + FN} \end{aligned} \tag{3.2}$$

3.9.3 Especificidade

A especificidade é responsável pela avaliação da porcentagem de ROIs normais detectadas de maneira correta. A Equação (3.3) descreve o cálculo dessa métrica (SAMPAT; MARKEY; BOVIK, 2005).

$$\begin{aligned} Especificidade &= \frac{\text{Total de verdadeiro-negativo (TN)}}{\text{Númer de ROIs normais}} \\ &= \frac{TN}{TN + FP} \end{aligned} \tag{3.3}$$

3.9.4 Valor Preditivo Positivo (VPP)

Métrica responsável pela avaliação da probabilidade do individuo que foi diagnosticado com o câncer de mama realmente tenha a doença.

$$VPP = \frac{TP}{TP + FP} \tag{3.4}$$

3.9.5 Valor Preditivo Negativo (VPN)

Métrica responsável pela avaliação da probabilidade do individuo que foi diagnosticado negativo realmente não tenha a doença.

$$VPN = \frac{TN}{TN + FN} \tag{3.5}$$

Capítulo

4

Este capítulo descreve em detalhes todos os resultados obtidos através do experimento apresentado no Capítulo 3. Além disso, é apresentado um comparativo entre os resultados das métricas calculadas com o objetivo de selecionar o melhor experimento para classificação de imagens mamográficas

RESULTADOS

4.1 EXPERIMENTOS COM A GLCM DA IMAGEM

Na primeira etapa serão gerados vetores de features baseados em entropias de Tsallis das matrizes de GLCM. Nesse caso, a maior dificuldade se concentra na escolha do parâmetro q. Assim sendo, foram realizadas investigações para direção fixa (θ) e distância fixa (d) das GLCM's, e coletados dados de entropia de Tsallis em faixas de intervalos, como se segue.

4.1.1 Experimento I sob direções fixas

Como foi descrito no Capítulo 3, o primeiro experimento utiliza os conceitos da matriz de co-ocorrência (GLCM) para uma direção fixa θ, onde $\theta \in \{0°, 45°, 90°, 135°\}$ e com uma variação da distância d, onde $d \in \{1, 2, 3, 4\}$. As GLCM's são extraídas a partir da imagem do entorno de uma massa de mamografia para o desenvolvimento das análises estatísticas.

4.1.1.1 Parâmetro q variando em $[0.1, 0.9]$ A Tabela 4.1 apresenta os resultados das cinco métricas estatísticas estabelecidas para nove valores diferentes do índice q dentro do intervalo $[0.1, 0.9]$, com um incremento de 0.1. As avaliações dos resultados foram feitas analisando os maiores valores de acurácia, sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo.

O valor de acurácia representa a quantidade de resultados corretos que o classificador inferir a partir da análise das *features* estabelecidas para o problema de classificação. Para esse primeiro experimento no intervalo $[0.1, 0.9]$, o maior valor de acurácia alcançado foi 87.4%, para os parâmetros $(q, \theta) = (0.6, 0°)$.

A medida de sensibilidade representa a quantidade de lesões anormais corretamente identificadas pelo classificador. Para os parâmetros $(q, \theta) = (0.6, 0^\circ)$ a sensibilidade obtida foi de 86.2%. Tal valor também foi o maior obtido dentre os experimentos para direções fixas. A medida de especificidade infere a probabilidade de o método identificar indivíduos sem massa. Para o par $(q, \theta) = (0.6, 0^\circ)$ a especificidade foi de 88.6%. Assim sendo, para tal par de parâmetros o método se apresenta melhor na identificação de indivíduos sem massa. Por outro lado, a maior sensibilidade obtida foi de 93.1%, para $(q, \theta) = (0.7, 0^\circ)$ e $(q, \theta) = (0.9, 135^\circ)$.

O método se apresenta com sensibilidade maior que a especificidade para os parâmetros $(q, \theta) = (0.4, 45^\circ)$, $(q, \theta) = (0.5, 90^\circ)$ e $(q, \theta) = (0.7, 90^\circ)$. Entretanto uma performance mais equilibrada pode ser vista em $(q, \theta) = (0.5, 135^\circ)$ com todas medidas iguais a 84.2%. Por fim, as duas últimas medidas apresentadas nesse experimento são utilizadas para medir a porcentagem de confiabilidade do método desenvolvido, onde o maior valor de VPP foi 92.2% para $(q, \theta) = (0.7, 0^\circ)$ e o maior valor de VPN foi 86.5% para $(q, \theta) = (0.6, 0^\circ)$.

A Tabela B.1, do Apêndice B, apresenta todos os resultados obtidos nesse experimento.

Tabela 4.1 Resultados da GLCM da imagem para θ fixo no intervalo $[0.1, 0.9]$

q	θ	γ	C	**Estatísticas (%)**				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
0.6	0°	32768	0.0078125	87.4	86.2	88.6	88.3	86.5
0.7	0°	512	0.03125	87.2	81.3	93.1	92.2	83.3
0.9	135°	32768	0.00195312	86.4	79.7	93.1	92.0	82.1

4.1.1.2 Parâmetro q variando em $[1.1, 1.9]$ Com o objetivo de melhorar os valores de acurácia e consequentemente reduzir o número de resultados falso-positivos, o segundo experimento foi desenvolvido utilizando um novo vetor de valores para q, onde $q \in [1.1, 1.9]$, com um incremento de 0.1. O maior valor de acurácia obtido foi de 89.8% para os parâmetros $(q, \theta) = (1.3, 0^\circ)$ e $(q, \theta) = (1.4, 0^\circ)$. No primeiro caso, registrou-se taxas de 84.2% e 95.5% de sensibilidade e especificidade, respectivamente. E no segundo caso, taxas de 85.4% e 94.3% de sensibilidade e especificidade. Uma maior sensibilidade no intervalo em questão foi obtido para $(q, \theta) = (1.9, 0^\circ)$, a uma taxa de 86.2%.

Quanto à maior especificidade foi de 96.3% para $(q, \theta) = (1.2, 0^\circ)$. Em ambos os casos o método ainda é melhor para identificação de indivíduos sem massa. Nota-se ainda que para os parâmetros $(q, \theta) = (1.5, 135^\circ)$, $(q, \theta) = (1.9, 45^\circ)$ e $(q, \theta) = (1.9, 135^\circ)$, o método se mostra mais eficiente na identificação de indivíduos com massa, na faixa de intervalo em questão. Nesses casos, com valores de acurácia médio em torno de 79.3%.

A Tabela B.2, no Apêndice B, apresenta todos os resultados obtidos nesse experimento.

Tabela 4.2 Resultados da GLCM da imagem para θ fixo no intervalo $[1.1, 1.9]$

q	θ	γ	C	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.3	0°	2048	0.03125	89.8	84.2	95.5	94.9	85.8
1.4	0°	32768	0.0078125	89.8	85.4	94.3	93.7	86.6
1.9	0°	512	0.0078125	87.8	86.2	89.4	89.1	86.6

A partir dos resultados apresentados na Tabelas 4.1 e 4.2 foram analisados todos os valores de acurácia com o objetivo de extrair os maiores valores para compôr os experimentos 4.1.1.3 e 4.1.1.4. Desse modo, os valores de $q = 1.3$ e $q = 1.4$ proporcionaram os melhores resultados de acurácia, ambos iguais à 89.8%.

4.1.1.3 Parâmetro q variando em $[1.31, 1.39]$ Baseado nos resultados alcançados nos intervalos $[0.1, 0.9]$ e $[1.1, 1.9]$, é proposto aqui refinar um subintervalo compreendido no segundo supracitado intervalo. Analisando os dados do intervalo $[1.31, 1.39]$ chega-se a uma acurácia máxima de 91.3% para os parâmetros $(q, \theta) = (1.31, 0°)$.

Para os parâmetros $(q, \theta) = (1.31, 0°)$ foram encontrados não só maior acurácia, mas também a maior taxa de sensibilidade, 89.0%. Entretanto, a especificidade, nesse caso, ainda é maior que a taxa de sensibilidade, a saber, 93.5%. Isso aponta para a eficiência do método em identificar amostras sem massa.

A Tabela 4.3 apresenta alguns resultados obtidos nesse experimento. Os demais resultados desse experimento podem ser encontrados na Tabela B.3 (Apêndice B).

Tabela 4.3 Resultados da GLCM da imagem para θ fixo no intervalo $[1.31, 1.39]$

q	θ	C	γ	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.31	0°	32768	0.0078125	91.3	89.0	93.5	93.2	89.5
1.37	0°	32768	0.00195312	90.2	84.6	95.9	95.4	86.1

4.1.1.4 Parâmetro q variando em $[1.41, 1.49]$ Também baseado nos dados encontrados para os intervalos $[0.1, 0.9]$ e $[1.1, 1.9]$, um segundo subintervalo intervalo foi criado para refinar um resultado encontrado na Tabela 4.2. A partir desse novo intervalo, obteve-se uma acurácia máxima de 89.6%, para os parâmetros $(q, \theta) = (1.49, 0°)$. Para o mesmo par de parâmetros, foi encontrado o maior valor de especificidade, com uma porcentagem igual a 96.7%.

Tabela 4.4 Resultados da GLCM da imagem para θ fixo no intervalo $[1.41, 1.49]$

q	θ	C	γ	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.45	0°	32768	0.03125	86.6	89.8	83.4	84.4	89.1
1.49	0°	2048	0.0078125	89.6	82.5	96.7	96.2	84.7

O maior valor de sensibilidade encontrado está associado ao par $(q, \theta) = (1.45, 0°)$. Ou seja, esse par indica maior capacidade de identificação dos indivíduos doentes.

4.1.2 Experimento II sob distâncias fixas

O segundo experimento consiste na utilização dos conceitos da matriz de co-ocorrência (GLCM) para uma distância fixa d, onde $d \in \{1, 2, 3, 4\}$ e com uma variação das direções θ, onde $\theta \in \{0°, 45°, 90°, 135°\}$. As GLCM's são extraídas a partir da imagem do entorno de uma massa de mamografia para o desenvolvimento das análises estatísticas.

4.1.2.1 Parâmetro q variando em $[0.1, 0.9]$ A partir da análise da Tabela 4.5, pode-se perceber que o melhor valor de acurácia encontrado foi para os parâmetros $(q, d) = (0.7, 1)$, com uma porcentagem de 88.5%. Além do valor de acurácia máximo, a partir dos parâmetros supracitados, foi possível obter o maior valor preditivo negativo desse método, com uma porcentagem de 84.7%.

Tabela 4.5 Resultados da GLCM da imagem para d fixo no intervalo $[0.1, 0.9]$

q	θ	C	γ	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
0.6	0°	32768	0.000488281	86.6	76.9	96.4	95.5	80.7
0.7	0°	32768	0.00195312	88.5	83.0	93.9	93.2	84.7
0.8	45°	128	0.5	82.2	85.8	78.5	80.0	84.7

Já para as medidas de sensibilidade, o melhor valor encontrado foi 85.8% para os parâmetros $(q, d) = (0.8, 2)$, indicando um bom resultado para classificação de amostras com massas. Por fim, para o valor de especificidade encontrado foi para os parâmetros $(q, d) = (0.6, 1)$, com a porcentagem 96.4%. A Tabela B.5 apresenta todos os resultados obtidos nesse experimento.

4.1.2.2 Parâmetro q variando em $[1.1, 1.9]$ O segundo experimento envolvendo as GLCM's de distância fixa da imagem apresentou resultados bastante significativos

para esse trabalho, como pode ser vista na Tabela 4.6. Analisando os valores de acurácia, pode-se perceber que o valor máximo encontrado foi 91.3%, para os parâmetros $(q, d) = (1.1, 1)$. Esse valor se iguala ao valor encontrado no experimento da Seção 4.1.1.3. Desse modo, é possível concluir que ambos os métodos podem ser considerados bons classificadores para o problema de diagnóstico de massas e não-massas.

Para os valores de sensibilidade, encontra-se o maior resultado para os parâmetros $(q, d) = (1.9, 1)$, com a porcentagem de 88.7%. Já para o resultado de especificidade, o melhor resultado foi encontrado nos parâmetros $(q, d) = (1.5, 1)$, com porcentagens 97.6%. Em comparação com o resultado de sensibilidade, a classificação de amostras sem massa pode ser considerada mais eficiente para esse método. A Tabela B.6, no Apêndice B, apresenta todos os resultados obtidos nesse experimento.

Tabela 4.6 Resultados da GLCM da imagem para d fixo no intervalo $[1.1, 1.9]$

q	θ	C	γ	**Estatísticas (%)**				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.1	1	8192	0.03125	91.3	87.0	95.5	95.1	88.1
1.5	1	512	0.03125	88.1	78.5	97.6	97.0	82.0
1.9	1	32768	0.0078125	87.2	88.7	85.8	86.2	88.3

4.1.2.3 Parâmetro q variando em $[1.11, 1.19]$ O último método dos estudos com a matriz de co-ocorrência das imagens de mamografia foi desenvolvido a partir dos resultados obtidos no experimento 4.1.2.2. Analisando as Tabelas 4.5 e 4.6, é possível observar que o melhor valor de acurácia encontrado foi para $q = 1.1$, com uma distância fixa $d = 1$. Desse modo, para o Experimento 4.1.2.3 foi delimitado um novo intervalo para os valores dos índices q, onde $q \in [1.11, 1.19]$. A partir dos resultados das métricas, a Tabela 4.7 foi elaborada e avaliada.

Tabela 4.7 Resultados da GLCM da imagem para d fixo no intervalo $[1.11, 1.19]$

q	d	C	γ	**Estatísticas (%)**				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.15	1	2048	0.03125	90.3	83.4	97.2	96.7	85.4
1.16	1	2048	0.0078125	86.6	75.3	98.0	97.4	79.9
1.19	2	8192	0.0078125	88.1	86.2	89.9	89.5	86.7

Para os valores de acurácia, o melhor resultado encontrado foi 90.3% para os parâmetros $(q, d) = (1.15, 1)$. Fazendo um breve comparativo entre o melhor valor

de acurácia encontrada no Experimento 4.1.2.2. Os parâmetros $(q, d) = (1.11, 1)$ e $(q, d) = (1.15, 1)$ são considerados bons para melhor identificação de amostras sem massa do que para identificação de amostras com massa. Já os parâmetros $(q, d) = (0.1, 2), (0.8, 2), (1.9, 1)$ são melhores para identificação de amostras com massas do que para identificação daquelas que não possuem massa.

A Tabela B.7, no Apêndice B, apresenta todos os resultados obtidos nesse experimento.

4.2 EXPERIMENTOS COM A SVD DA GLCM

Os experimentos a seguir são baseados na extração de *features* a partir da matriz de valores singulares (SVD), calculada utilizando a matriz de co-ocorrência das regiões de interesse (ROIs) extraídas a partir das imagens de mamografia que compõem a base de dados desse trabalho.

O vetor de *features* é dado pela entropia de Tsallis dos valores singulares da SVD obtida de uma GLCM para o nível de quantização k, onde $k \in \{3, 4, 5, 6, 7, 8\}$

4.2.1 Experimento I sob direções fixas

Como também foi descrito no Capítulo 3, o primeiro experimento utiliza os conceitos de decomposição em valores singulares (SVD) a partir matriz de co-ocorrência (GLCM) para uma direção fixa θ, onde $\theta \in \{0°, 45°, 90°, 135°\}$ e com uma variação da distância d, onde $d \in \{1, 2, 3, 4\}$.

Tabela 4.8 Resultados da SVD a partir GLCM da imagem para θ fixo no intervalo $[0.1, 0.9]$

q	θ	C	γ	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
0.1	90°	128	0.125	63.0	39.3	86.6	74.6	58.8
0.8	0°	32	0.5	78.9	79.4	78.5	78.7	79.2
0.9	135°	128	0.03125	78.1	74.9	81.4	80.1	76.4

4.2.1.1 Parâmetro q variando em $[0.1, 0.9]$ O primeiro experimento foi desenvolvido utilizando o primeiro intervalo previamente selecionado, onde o q começa em 0.1 e vai até 0.9, com incremento de 0.1, resultando também em um total de noves valores a serem testados. A Tabela 4.8 apresenta todos os resultados encontrados para esse experimento.

Analisando os valores de acurácia, pode-se destacar que o valor máximo encontrado foi 79.8% para os parâmetros $(q, \theta) = (0.7, 0°)$. Os último valor analisado, foi o de especificidade. Para esse método, o valor máximo encontrado foi 86.6%, para os parâmetros $(q, \theta) = (0.1, 90°)$. A Tabela B.8, no Apêndice B, apresenta todos os resultados obtidos nesse experimento.

4.2.1.2 Parâmetro q variando em $[1.1, 1.9]$ Para a segunda etapa dos experimentos envolvendo SVD, foi delimitado o intervalo de $q = 1.1$ até $q = 1.9$. Em comparação com os resultados obtidos no experimento anterior, o Experimento 4.2.1.2 apresenta resultados consideravelmente melhores.

Para os valores de acurácia, o maior valor encontrado foi 82.4% tanto para o parâmetros $(q, \theta) = (1.8, 0^\circ)$. Analisando separadamente os valores de sensibilidade e especificidade, nota-se que o primeiro valor supera o segundo para os parâmetros $(q, \theta) = (0.1, 0^\circ), (0.3, 90^\circ), (0.4, 90^\circ), (0.4, 135^\circ), (0.6, 135^\circ), (0.7, 90^\circ)$ e $(0.8, 0^\circ)$, como podem ser visto na Tabela B.9 (Apêndice B).

Tabela 4.9 Resultados da SVD a partir GLCM da imagem para θ fixo no intervalo $[1.1, 1.9]$

q	θ	C	γ	**Estatísticas (%)**				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.3	0°	32	0.125	79.8	71.3	88.3	85.9	75.4
1.8	0°	2048	0.0078125	82.4	78.9	85.8	84.8	80.3
1.9	0°	2048	0.0078125	81.2	85.0	77.3	78.9	83.8

A partir das análises feitas anteriormente, foi selecionado o maior valor de acurácia encontrado nos experimentos 4.2.1.1 e 4.2.1.2 para compôr o último experimento desse trabalho. Semelhante ao que foi apresentado na Sessão 4.1.1.3, foi escolhido o valor 82.2%, obtido através do $q = 1.5$ e a partir desse valor, foi criado um novo intervalo de valores de teste de q. Esse intervalo é iniciado em $q = 1.81$ e vai até o $q = 1.89$, com uma variação de 0.1 entre os valores. Assim como todos os experimentos elaborados até aqui, teremos um total de nove valores diferentes de q para o desenvolvimento desse experimento.

A Tabela B.9, no Apêndice B, apresenta todos os resultados obtidos nesse experimento.

4.2.1.3 Parâmetro q variando em $[1.81, 1.89]$ O último método para direção fixa envolvendo SVD apresentou resultados maiores que os métodos apresentados nas Seções 4.2.1.1 e 4.2.1.2, concluindo que a decomposição em valores singulares também pode ser utilizada para o diagnóstico de mamografias normais e anormais, desde que seja escolhido um valor de q adequado. Para os resultados de acurácia apresentados na Tabela 4.10, o melhor valor encontrado foi 84.4% para para os parâmetros $(q, \theta) = (1.88, 0^\circ)$. Em um breve comparativo com o melhor resultado de acurácia obtido nos experimentos da Sessão 4.1.1.3, é possível notar que a diferença entre eles é de aproximadamente 7%.

Os melhores valores encontrados para as medidas de sensibilidade e especificidade foram de 85.8% e 89.1%, respectivamente. Ambos os resultados estão acima de 80%, o que significa que a SVD, para esse intervalo de q, pode ser considerado um bom classificador para diagnóstico de amostras negativas e positivas. Nesse experimento

nota-se também um maior número de casos com sensibilidade mais alta do que a especificidade, totalizando 14 casos. A Tabela B.10 apresenta todos os resultados obtidos nesse experimento.

Tabela 4.10 Resultados da SVD a partir GLCM da imagem para θ fixo no intervalo $[1.81, 1.89]$

q	θ	C	γ	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.83	0°	128	0.125	79.4	69.6	89.1	86.4	74.6
1.88	0°	32	0.5	84.4	85.4	83.4	83.7	85.1
1.89	0°	8192	0.0078125	80.8	85.8	75.7	77.9	84.2

4.2.2 Experimento II sob distâncias fixas

O Experimento 4.2.2 inicia os testes com uma distância fixa d (onde $(d \in 1, 2, 3, 4)$) para o cálculo das matrizes de valores singulares a partir da GLCM da imagem. Assim como o experimento apresentado na Seção 4.1.2.1, o intervalo escolhido foi $[0.1, 0.9]$, com um incremento de 0.1, totalizando 9 valores de q.

4.2.2.1 Parâmetro q variando em $[0.1, 0.9]$ Para as medidas de acurácia, VPP e VPN) os melhores valores encontrados foram para um valor os parâmetros $(q, d) = (0.9, 1)$. As porcentagens encontradas foram 79.8%, 83.0 e 77.1%, respectivamente. Esses resultados indicam que para a classificação de amostras verdadeiramente positivas, o experimento não apresentou valores favoráveis, tendo em vista que a porcentagem foi abaixo de 80%. Por outro lado, para a classificação de amostras verdadeiramente negativas, o Experimento 4.2.2.1 pode ser considerado favorável. Para a medida de sensibilidade, o melhor resultado encontrado foi para os parâmetros $(q, d) = (0.9, 2)$ e para a especificidade, os parâmetros $(q, d) = (0.4, 3)$ alcançaram o valor máximo, com 87.0% (ver Tabela 4.11).

A Tabela B.11 apresenta todos os resultados obtidos nesse experimento.

Tabela 4.11 Resultados da SVD a partir GLCM da imagem para d fixo no intervalo $[0.1, 0.9]$

q	d	C	γ	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
0.4	3	8.0	0.5	64.6	42.1	87.0	76.5	60.1
0.9	1	8192	0.0078125	79.8	74.9	84.6	83.0	77.1
	2	32768	0.0078125	69.2	76.1	62.3	66.9	72.3

4.2.2.2 Parâmetro q variando em $[1.1, 1.9]$ O valor máximo de acurácia encontrado foi 82.0%, para os parâmetros $(q, d) = (1.5, 1)$ e para os parâmetros $(q, d) = (1.7, 1)$. Esse valor pode ser considerado favorável, tendo em vista que acima de 80%.Entretanto, se comparamos com os valores apresentados nos experimentos envolvendo apenas a matriz de co-ocorrência da imagem, pode-se observar que os resultados envolvendo a SVD da matriz de co-ocorrência apresenta valores mais baixos (ver Tabela 4.12). A Tabela B.12, no Apêndice B, apresenta todos os resultados obtidos nesse experimento.

Tabela 4.12 Resultados da SVD a partir GLCM da imagem para d fixo no intervalo $[1.1, 1.9]$

q	d	C	γ	**Estatísticas (%)**				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.4	1	8192	0.03125	80.8	72.1	89.5	87.3	76.2
1.5	1	512	0.125	82.0	75.3	88.7	86.9	78.2
1.9	1	2048	0.0078125	80.2	80.2	80.2	80.2	80.2

4.2.2.3 Parâmetro q variando em $[1.71, 1.79]$ A partir dos resultados obtidos nas Seções 4.2.2.1 e 4.2.2.2, foi selecionado o melhor valor de acurácia para criação de um novo intervalo de valores do índice q para a elaboração do último experimento desse trabalho. Tendo em vista que o melhor valor de acurácia foi igual à 82.0%, para os parâmetros$(q, d) = (1.7, 1)$, o novo intervalo foi delimitado em $[1.71, 1.79]$ para avaliação das métricas presentes nesses 9 valores (ver Tabela 4.13).

Inicialmente, é possível perceber que os resultados apresentaram valores superiores aos resultados apresentados no Experimento 4.2.2.1 e Experimento 4.2.2.2. Desse modo, a melhor acurácia obtida foi 84.2%, para os parâmetros $(q, d) = (1.76, 1)$.

A Tabela B.13 apresenta todos os resultados obtidos nesse experimento.

Tabela 4.13 Resultados da SVD a partir GLCM da imagem para d fixo no intervalo $[1.71, 1.79]$

q	d	C	γ	**Estatísticas (%)**				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.71	1	2048	0.03125	81.4	80.6	82.2	81.9	80.9
1.76	1	32768	0.0078125	84.2	79.8	88.7	87.6	81.4
1.79	1	2048	0.0078125	82.6	74.5	90.7	88.9	78.0

Analisando detalhadamente cada tabela apresentada, podemos concluir que os dois melhores resultados foram obtidos através da extração de *features* a partir das matrizes de co-ocorrência das ROIs extraídas das imagens de mamografias. O primeiro melhor resultado foi encontrado para um θ fixo, utilizando os parâmetros $(q, \theta) =$

$(1.31, 0^\circ)$ através de blocos de tamanho 64×64. Esse teste foi elaborado na Seção 4.1.1.3 e obteve um valor de acurácia igual a 91.3%. É possível destacar também, os valores de sensibilidade e especificidade encontrados para esses parâmetros que foram iguais à 89.0% e 93.5%, respectivamente.

O segundo melhor resultado foi obtido nos experimentos envolvendo uma distância fixa d, onde o valor máximo de acurácia foi, também, igual à 91.3%, para os parâmetros $(q, d) = (1.1, 1)$.

Aplicando os conceitos apresentados no segundo experimento a partir da seleção da melhor acurácia, a decomposição em valores singulares foi implementada a partir da Seção 4.2 e, seguindo o mesmo princípio descrito anteriormente, foi possível encontrar um valor de acurácia igual a 84.4% para para os parâmetros $(q, \theta) = (1.88, 0^\circ)$, a partir de uma direção fixa $\theta = 0^\circ$ e variação de distância $d = \{1, 2, 3, 4\}$. Esse resultado também pode ser considerado adequado para o problema proposto nesse trabalho.

Capítulo

5

O capítulo descreve as principais conclusões obtidas através da análisde dos resultados apresentados no Capítulo 4. São abordados todos os testes desenvolvidos e as conclusões obtidas através da observação do comportamento de cada teste para o processo de classificação de imagens de mamografia

CONCLUSÃO

Esse trabalho teve como principal objetivo o estudo e implementação de métodos para extração de conjuntos de vetores de *features* para classificação de massas retiradas a partir de imagens mamógraficas previamente delimitadas por um radiologista.

No inicio da elaboração desse trabalho, várias pesquisas foram desenvolvidas a partir da leitura de artigos para a definição de um conjunto de métodos que seriam utilizados para extração das *features*. A partir dessa etapa, foram escolhidos dois métodos envolvendo matrizes de co-ocorrência e decomposição em valores singulares. A partir dessas duas matrizes calculadas a partir da imagem de mamografia pré-processada, foi testado o comportamente da Entropia de Tsallis como *feature* para classificação das massas. Para tanto, foram necessários vários testes para encontrar qual o melhor valore do índice q para se obter os melhores valores de acurácia, sensibilidade, especificidade, VPP e VPN.

A etapa seguinte envolveu um estudo acerca dos métodos de aprimoramento da qualidade da imagem, tendo em vista que a base de dados DDSM apresenta imagens mamógraficas contendo parte da massa peitoral da paciente e além disso, contendo informações como número de registro do paciente. Para que esses fatores não pudessem influenciar nos valores das *features*, foi implementado um método para extração de regiões de interesse e posteriormente, um método para equalização da imagem, também com o objetivo de realçar os valores dos *pixels* dessas ROIs.

O método para extração das ROIS envolveu a leitura do *Chain Code* delimitado pela própria base, com um estudo prévio feito por um radiologista. A partir disso, para cada imagem foi extraída uma ROI de dimensão 64×64 a partir do ponto médio de cada massa da imagem. Ao total, foram selecionadas e extraídas 247 ROIs pertencentes à mamografias normais e 247 ROIs pertencentes à mamografias anormais (benignas e malignas). Todas essas novas imagens foram equalizadas com um algoritmo baseado nos conceitos básicos de equalização de imagem. Frisa-se aqui, a uniformidade dos dados utilizados em termos de quantidade de regiões de massa e não massa.

A última etapa envolveu o processo de desenvolvimento e aplicação de oito testes para extração de *features* e validação desses métodos a partir da análise das cinco métricas (acurácia, sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo). No Capítulo 4 foram apresentados todas as abordagens utilizadas pelos oito experimentos e seus respectivos resultados.

Conclui-se então que os vetores de features dados pelas entropias de Tsallis das GLCMs são mais eficientes no processo de classificação de massas/não massas, do que para a SVD das GLCMs.

Apêndice

A

Neste apêndice estão descritos os fundamentos básicos da álgebra linear para compreensão de algumas etapas descritas nesse trabalho

APÊNDICE A

A.1 FUNDAMENTOS DA ÁLGEBRA LINEAR

A.1.1 Rank da matriz

Um vetor coluna v de tamanho $N \times 1$ é considerado nulo quando todas as suas entradas são nulas. Logo,

$$v = \begin{bmatrix} 0 \\ 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \tag{A.1}$$

O *rank* de uma matriz A de ordem $M \times N$ pode ser então definido como o número de vetores linhas não-nulos dessa matriz (STRANG, 2006).

A.1.2 Matriz Diagonal

Uma matriz A de ordem $N \times N$, é chamada de matriz diagonal quando todos os elementos a_{ij}, com $i \neq j$, são nulos. Ou seja, todos os elementos da matriz, exceto os elementos da diagonal principal ($i = j$) são iguais a 0 (STEINBRUCH; WINTERLE, 1990).

A.1.3 Vetores Ortogonais e Ortonormais

Dois vetores v_1 e v_2 são chamados de vetores ortogonais, representados por $v_1 \perp v_2$, se e somente se, em um dado espaço vetorial V, o produto interno entre eles é nulo (STEINBRUCH; WINTERLE, 1990). A Equação (A.2) expressa a condição descrita:

$$< v_1, v_2 >= 0 \tag{A.2}$$

onde $< ., . >: V \times V \rightarrow R$ é um produto interno definido em V. Além disso, se v_1 e v_2 são unitários, eles são chamados vetores ortonormais.

A.1.4 Matriz Ortogonal

Uma matriz A de ordem $N \times N$, é chamada de matriz ortogonal se sua matriz inversa é igual a sua transposta (STEINBRUCH; WINTERLE, 1990), como pode ser visto na Equação (A.3)

$$A^{-1} = A^T \tag{A.3}$$

Logo,

$$A \cdot A^T = A^T \cdot A = I \tag{A.4}$$

onde I é a matriz identidade $N \times N$.

A.1.5 Autovetores e Autovalores

Sendo A uma matriz quadrada de ordem $N \times N$, definimos λ como autovalor de A se existir um vetor não-nulo, $v \in R^n$, que satisfaça a condição:

$$Av = \lambda v \tag{A.5}$$

Todos os vetores não-nulos v que satisfazem a Equação (A.5) são chamados de autovetores da matriz A correspondendo ao autovalor λ.

A.1.6 Matrizes singulares e não-singulares

Sendo A uma matriz quadrada de ordem $N \times N$, A é uma matriz singular se o $det(A) = 0$. Se $det(A) \neq 0$, então a matriz é não-singular ou matriz regular (STRANG, 2006).

Apêndice

B

Neste apêndice estão apresentados todas as tabelas completas de resultados elaboradas a partir dos experimentos descritos no Capítulo 3

APÊNDICE B

Tabela B.1 Resultados da GLCM da imagem para θ fixo no intervalo $[0.1, 0.9]$

q	θ	γ	C	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
0.1	0°	2048	0.0078125	83.1	78.1	88.2	86.9	80.1
	45°	2048	0.0078125	77.3	68.4	86.2	83.2	73.1
	90°	2048	0.0078125	77.7	70.8	84.6	82.1	74.3
	135°	2048	0.0078125	80.3	73.2	87.4	85.3	76.5
0.2	0°	2048	0.03125	86.2	83.8	88.6	88.0	84.5
	45°	32768	0.00195312	79.1	73.2	85.0	83.0	76.0
	90°	8	0.5	77.1	72.8	81.3	79.6	75
	135°	2048	0.0078125	79.9	76.1	83.8	82.4	77.8
0.3	0°	2048	0.03125	85.4	81.3	89.4	88.5	82.7
	45°	32768	0.00195312	79.9	75.3	84.6	83.0	77.4
	90°	32768	0.00195312	74.8	63.5	86.2	82.1	70.2
	135°	2048	0.0078125	81.7	74.4	89.0	87.2	77.7
0.4	0°	32768	0.00195312	84.2	75.7	92.7	91.2	79.2
	45°	32768	0.00195312	78.5	79.3	77.7	78.0	79.0
	90°	512	0.0078125	78.1	72.4	83.8	81.7	75.2
	135°	128	0.03125	78.9	69.6	88.2	85.5	74.4
0.5	0°	2048	0.000488281	80.3	72.0	88.6	86.4	76.0
	45°	2048	0.0078125	78.3	72.0	84.6	82.4	75.1
	90°	8192	0.125	77.7	79.7	75.7	76.6	78.9
	135°	2048	0.03125	84.2	84.2	84.2	84.2	84.2
0.6	0°	32768	0.0078125	87.4	86.2	88.6	88.3	86.5
	45°	32768	0.0078125	82.1	80.1	84.2	83.5	80.9
	90°	128	0.03125	79.1	71.6	86.6	84.2	75.3
	135°	8192	0.00195312	84.6	79.7	89.4	88.3	81.5
0.7	0°	512	0.03125	87.2	81.3	93.1	92.2	83.3
	45°	32768	0.000488281	75.3	61.5	89.0	84.9	69.8
	90°	32	2	71.8	78.1	65.5	69.4	75.0
	135°	128	0.03125	80.3	71.2	89.4	87.1	75.6
0.8	0°	8	0.125	82.7	81.7	83.8	83.4	82.1
	45°	32768	0.0078125	82.7	78.5	87.0	85.8	80.2
	90°	32768	0.00012207	80.3	72.4	88.2	86.0	76.2
	135°	32768	0.00195312	85.0	80.1	89.8	88.7	81.9
0.9	0°	8192	0.00195312	81.5	76.5	86.6	85.1	78.6
	45°	32768	0.00195312	79.3	77.3	81.3	80.5	78.2
	90°	8192	0.0078125	78.3	74.8	81.7	80.4	76.5
	135°	32768	0.00195312	86.4	79.7	93.1	92.0	82.1

Tabela B.2 Resultados da GLCM da imagem para θ fixo no intervalo $[1.1, 1.9]$

q	θ	γ	C	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.1	0°	32768	0.0078125	86.4	84.2	88.6	88.1	84.8
	45°	512	0.03125	81.1	78.5	83.8	82.9	79.6
	90°	512	0.0078125	74.7	70.4	78.9	77.0	72.8
	135°	32768	0.00195312	85.0	80.5	89.4	88.4	82.1
1.2	0°	512	0.03125	83.6	70.8	96.3	95.1	76.7
	45°	2048	0.0078125	81.7	76.9	86.6	85.2	78.9
	90°	2048	0.0078125	82.5	81.7	83.4	83.1	82.0
	135°	32768	0.00195312	84.2	79.3	89.0	87.8	81.1
1.3	0°	2048	0.03125	89.8	84.2	95.5	94.9	85.8
	45°	512	0.03125	79.1	74.4	83.8	82.1	76.6
	90°	32768	0.000488281	76.3	68.4	84.2	81.2	72.7
	135°	32768	0.0078125	84.8	83.8	85.8	85.5	84.8
1.4	0°	32768	0.0078125	89.8	85.4	94.3	93.7	86.6
	45°	512	0.125	79.1	75.7	82.5	81.3	77.2
	90°	32	0.5	77.1	77.3	76.9	77.0	77.2
	135°	32768	0.0078125	84.2	80.9	87.4	86.5	82.1
1.5	0°	2048	0.03125	87.0	78.1	95.9	95.0	81.4
	45°	2048	0.00195312	80.3	76.1	84.6	83.1	77.9
	90°	8	0.125	79.7	72.0	87.4	85.1	75.7
	135°	32768	0.125	78.5	86.6	70.4	74.5	84.0
1.6	0°	128	0.5	85.4	82.1	88.6	87.8	83.2
	45°	512	0.125	82.7	75.7	89.8	88.2	78.7
	90°	128	0.5	81.3	79.3	83.4	82.7	80.1
	135°	32768	0.000488281	80.7	73.2	88.2	86.1	76.7
1.7	0°	8192	0.125	86.4	80.9	91.9	90.9	82.8
	45°	8192	0.003125	81.1	79.7	82.5	82.0	80.3
	90°	2048	0.0078125	79.7	73.6	85.8	83.8	76.5
	135°	8192	0.00195312	80.3	75.7	85.0	83.4	77.7
1.8	0°	32768	0.125	85.2	84.6	85.8	85.6	84.8
	45°	128	0.5	77.5	67.2	87.8	84.6	72.8
	90°	512	0.0078125	83.4	78.9	87.8	86.6	80.6
	135°	32768	0.00012207	80.1	76.5	83.8	82.5	78.1
1.9	0°	512	0.0078125	87.8	86.2	89.4	89.1	86.6
	45°	8192	0.03125	79.9	82.5	77.3	78.4	81.6
	90°	32768	0.03125	76.3	73.6	78.9	77.7	75.0
	135°	8192	0.03125	79.5	81.3	77.7	78.5	80.6

Tabela B.3 Resultados da GLCM da imagem para θ fixo no intervalo $[1.31, 1.39]$

q	θ	C	γ	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.31	0°	32768	0.0078125	91.3	89.0	93.5	93.2	89.5
	45°	32768	0.00195312	83.4	82.5	84.2	83.9	82.8
	90°	8	2	77.7	72.0	83.4	81.2	74.9
	135°	32768	0.0078125	84.0	80.9	87.0	86.2	82.0
1.32	0°	512	0.125	85.2	85.4	85.0	85.0	85.3
	45°	512	0.03125	82.7	71.6	93.9	92.1	76.8
	90°	32768	0.03125	81.9	76.9	87.0	85.5	79.0
	135°	128	0.03125	76.9	73.7	80.2	78.8	75.3
1.33	0°	512	0.03125	86.8	80.5	93.1	92.1	82.7
	45°	2048	0.03125	84.4	77.3	91.4	90.0	80.1
	90°	32	0.125	82.3	85.0	79.7	80.7	84.1
	135°	2048	0.125	84.4	81.3	87.4	86.6	82.4
1.34	0°	2	0.5	80.9	75.3	86.6	84.9	77.8
	45°	32768	0.000488281	80.1	71.2	89.0	86.6	75.6
	90°	2048	0.0078125	79.9	70.0	89.8	87.3	75.0
	135°	32768	0.000488281	83.6	78.5	88.6	87.3	80.5
1.35	0°	512	0.03125	85.0	78.5	91.4	90.2	81.0
	45°	32768	0.0078125	82.7	79.3	86.2	85.2	80.6
	90°	32	0.5	78.7	84.2	73.2	75.9	82.2
	135°	32	0.5	82.1	76.9	87.4	85.9	79.1
1.36	0°	8	0.5	87.2	81.3	93.1	92.2	83.3
	45°	8192	0.00195312	78.1	73.2	82.9	81.1	75.6
	90°	32	0.03125	79.3	68.8	89.8	87.1	74.2
	135°	32768	0.00195312	84.8	78.9	90.6	89.4	81.1
1.37	0°	32768	0.00195312	90.2	84.6	95.9	95.4	86.1
	45°	2048	0.003125	83.6	79.7	87.4	86.4	81.2
	90°	128	0.125	79.1	73.6	84.6	82.7	76.2
	135°	8192	0.03125	83.4	82.1	84.6	84.2	83.4
1.38	0°	2048	0.125	83.4	82.9	83.8	83.6	83.1
	45°	8192	0.0078125	81.9	73.6	90.2	88.3	77.4
	90°	8	2	72.8	63.9	81.7	77.8	69.4
	135°	8192	0.0078125	85.6	80.5	90.6	89.6	82.3
1.39	0°	32768	0.00195312	87.6	84.6	90.6	90.0	85.4
	45°	8192	0.03125	82.7	81.7	83.8	83.4	82.1
	90°	8	0.5	76.9	68.4	85.4	82.4	73.0
	135°	128	0.0078125	69.2	74.4	63.9	67.3	71.4

Tabela B.4 Resultados da GLCM da imagem para θ fixo no intervalo $[1.41, 1.49]$

q	θ	C	γ	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.41	0°	8	0.5	85.4	82.5	88.2	87.5	83.5
	45°	8192	0.0078125	87.6	80.5	94.7	93.8	82.9
	90°	8192	0.00195312	77.9	75.7	80.1	79.2	76.7
	135°	2048	0.125	83.0	84.6	82.9	83.2	84.3
1.42	0°	2048	0.125	85.2	86.2	84.2	84.5	85.9
	45°	512	0.03125	82.1	75.3	89.0	87.3	78.2
	90°	32768	0.03125	80.3	72.0	88.6	86.4	76.0
	135°	512	0.03125	84.6	81.7	87.4	86.6	82.7
1.43	0°	8192	0.0078125	86.6	86.2	87.0	86.9	86.3
	45°	32768	0.0078125	85.0	81.7	88.2	87.4	82.8
	90°	2048	0.00195312	81.3	72.8	89.8	87.8	76.8
	135°	8192	0.03125	89.0	88.2	89.8	89.7	88.4
1.44	0°	2048	0.0078125	83.6	80.9	86.2	85.4	81.9
	45°	512	0.125	82.5	78.9	86.2	85.1	80.3
	90°	128	0.125	80.3	78.9	81.7	81.2	79.5
	135°	32768	0.0078125	85.2	80.5	89.8	88.8	82.2
1.45	0°	32768	0.03125	86.6	89.8	83.4	84.4	89.1
	45°	512	0.125	83.6	80.5	86.6	85.7	81.6
	90°	32768	0.0078125	85.4	81.7	89.0	88.2	83.0
	135°	32768	0.00195312	86.2	83.4	89.0	88.4	84.2
1.46	0°	512	0.0078125	85.2	74.4	95.9	94.8	79.0
	45°	32768	0.0078125	84.8	78.9	90.6	89.4	81.1
	90°	32768	0.00195312	82.1	80.1	84.2	83.5	80.9
	135°	2048	0.0078125	84.2	78.9	89.4	88.2	80.9
1.47	0°	512	0.0078125	85.0	88.2	81.7	82.8	87.4
	45°	128	0.5	79.9	76.9	82.9	81.8	78.2
	90°	128	0.5	82.7	82.9	82.5	82.6	82.9
	135°	512	0.03125	82.7	78.5	87.0	85.8	80.2
1.48	0°	512	0.5	80.3	83.4	77.3	78.6	82.3
	45°	2048	0.0078125	86.4	85.8	87.0	86.8	86.0
	90°	8	0.5	78.5	68.0	89.0	86.1	73.5
	135°	2048	0.125	84.8	87.0	82.5	83.3	86.4
1.49	0°	2048	0.0078125	89.6	82.5	96.7	96.2	84.7
	45°	32768	0.000488281	79.3	75.7	82.9	81.6	77.3
	90°	128	0.5	79.1	76.9	81.3	80.5	77.9
	135°	128	0.5	81.1	74.0	88.2	86.3	77.3

Tabela B.5 Resultados da GLCM da imagem para d fixo no intervalo $[0.1, 0.9]$

q	θ	C	γ	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
0.1	1	2048	0.03125	81.2	79.9	85.4	84.1	78.7
	2	512	0.125	78.3	83.0	73.7	75.9	81.3
	3	8192	0.0078125	74.5	72.5	76.5	75.5	73.5
	4	2048	0.125	68.6	67.6	69.6	69.0	68.3
0.2	1	8192	0.0078125	85.4	82.2	88.7	87.9	83.3
	2	512	0.03125	79.8	65.2	94.3	92.0	73.0
	3	8192	0.000488281	68.0	44.1	91.9	84.5	62.2
	4	2.0	0.5	67.0	46.2	87.9	79.2	62.0
0.3	1	8192	0.001953125	85.6	81.4	89.9	88.9	82.8
	2	32	0.125	78.9	68.8	89.1	86.3	74.1
	3	32768	0.000488281	74.7	60.7	88.7	84.3	69.3
	4	128	0.03125	70.9	57.5	84.2	78.5	66.5
0.4	1	32	0.5	82.2	79.4	85.0	84.1	80.5
	2	32768	0.000488281	81.6	68.8	94.3	92.4	75.2
	3	512	0.03125	79.1	78.9	79.4	79.3	79.0
	4	2048	0.125	65.0	62.3	67.6	65.8	64.2
0.5	1	2048	0.0078125	83.6	71.3	96.0	94.6	79.9
	2	512	0.03125	83.6	72.9	94.3	92.8	77.7
	3	2048	0.03125	78.3	74.9	81.8	80.4	76.5
	4	8192	0.125	67.4	65.6	69.2	68.1	66.8
0.6	0°	32768	0.000488281	86.6	76.9	96.4	95.5	80.7
	45°	2048	0.0078125	85.2	78.5	91.9	90.7	81.1
	90°	8192	0.00195312	77.7	65.6	89.9	86.6	72.3
	135°	2048	0.000488281	75.3	65.6	85.0	81.4	71.2
0.7	1	32768	0.00195312	88.5	83.0	93.9	93.2	84.7
	2	2048	0.0078125	80.8	69.6	91.9	89.5	75.2
	3	8192	0.0078125	77.1	72.5	81.8	79.9	74.8
	4	32768	0.000488281	69.0	59.5	78.5	73.5	66.0
0.8	1	2048	0.0078125	88.1	81.0	95.1	94.3	83.3
	2	128	0.5	82.2	85.8	78.5	80.0	84.7
	3	32768	0.0078125	78.9	72.5	85.4	83.3	75.6
	4	32768	0.00195312	74.3	68.8	79.8	77.3	71.9
0.9	1	32	0.125	87.2	83.0	91.5	90.7	84.3
	2	32768	0.0078125	84.0	82.6	85.4	85.0	83.1
	3	8192	0.03125	78.7	82.2	75.3	76.9	80.9
	4	32768	0.000488281	70.9	61.5	80.2	75.6	67.6

Tabela B.6 Resultados da GLCM da imagem para d fixo no intervalo $[1.1, 1.9]$

q	θ	C	γ	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.1	1	8192	0.03125	91.3	87.0	95.5	95.1	88.1
	2	8192	0.0078125	85.2	81.8	88.7	87.8	83.0
	3	32	0.5	76.5	70.4	82.6	80.2	73.6
	4	32768	0.00195312	79.1	77.7	80.6	80.0	78.3
1.2	1	32768	0.03125	87.0	86.2	87.9	87.7	86.5
	2	2048	0.03125	86.6	81.7	91.5	90.6	83.4
	3	8192	0.03125	76.5	67.2	85.8	82.6	72.4
	4	512	0.03125	70.4	57.1	83.8	77.9	66.1
1.3	1	8192	0.00195312	85.2	77.7	92.7	91.4	80.6
	2	2048	0.0078125	85.2	83.0	87.4	86.9	83.7
	3	32768	0.000488281	82.4	77.7	87.0	85.7	79.6
	4	32	0.125	73.7	68.4	78.9	76.5	71.4
1.4	1	8192	0.0078125	88.3	81.0	95.5	94.8	83.4
	2	512	0.125	83.6	80.2	87.0	86.1	81.4
	3	8192	0.03125	81.0	78.1	83.8	82.8	79.3
	4	8192	0.03125	72.7	68.0	77.3	75.0	70.7
1.5	1	512	0.03125	88.1	78.5	97.6	97.0	82.0
	2	32	0.5	83.6	82.2	85.0	84.6	82.7
	3	2048	0.0078125	77.1	74.9	79.4	78.4	76.0
	4	2048	0.03125	73.7	61.1	86.2	81.6	68.9
1.6	1	32768	0.00195312	89.7	83.8	95.5	95.0	85.5
	2	128	0.03125	83.4	74.9	91.9	90.2	78.5
	3	32768	0.00195312	80.4	70.9	89.9	87.5	75.5
	4	32768	0.000488281	69.4	71.7	67.2	68.6	70.3
1.7	1	8192	0.125	83.8	78.5	89.1	87.8	80.6
	2	512	0.0078125	81.8	70.4	93.1	91.1	75.9
	3	32768	0.000488281	80.6	72.5	88.7	86.5	76.3
	4	512	0.5	71.9	72.5	71.3	71.6	72.1
1.8	1	32768	0.000488281	87.7	80.7	94.7	93.9	83.0
	2	2048	0.0078125	86.0	79.4	92.7	91.6	81.8
	3	2048	0.03125	78.3	77.7	78.9	78.7	78.0
	4	32768	0.000488281	71.5	66.0	76.9	74.1	69.3
1.9	1	32768	0.0078125	87.2	88.7	85.8	86.2	88.3
	2	32768	0.0078125	81.4	77.3	85.4	84.1	79.0
	3	2048	0.00195312	72.1	52.2	91.9	86.6	65.8
	4	32768	0.00195312	75.1	73.7	76.5	75.8	74.4

Tabela B.7 Resultados da GLCM da imagem para d fixo no intervalo $[1.11, 1.19]$

q	d	C	γ	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.11	1	32768	0.001953125	88.3	81.0	95.5	94.8	83.4
	2	2048	0.0078125	84.8	80.6	89.1	88.1	82.1
	3	2048	0.0078125	80.6	72.1	89.1	86.8	76.1
	4	32768	0.000488281	77.9	72.1	83.8	81.7	75.0
1.12	1	32768	0.03125	86.0	85.4	86.6	86.5	85.6
	2	32768	0.0078125	84.4	76.1	92.7	91.2	79.5
	3	8192	0.0078125	78.9	72.5	85.4	83.3	75.6
	4	2048	0.0078125	70.4	68.4	72.5	71.3	69.6
1.13	1	8192	0.03125	86.0	80.6	91.5	90.5	82.5
	2	32768	0.001953125	87.2	82.2	92.3	91.4	83.8
	3	8.0	2.0	72.7	64.0	81.4	77.5	69.3
	4	32768	0.000488281	76.3	74.1	78.5	77.5	75.2
1.14	1	128	0.5	86.4	85.0	87.9	87.5	85.4
	2	512	0.125	85.2	78.5	91.9	90.7	81.1
	3	2048	0.03125	79.1	72.1	86.2	84.0	75.5
	4	32768	0.00012207	74.9	62.8	87.0	82.9	70.0
1.15	1	2048	0.03125	90.3	83.4	97.2	96.7	85.4
	2	32768	0.000488281	85.4	81.0	89.9	88.9	82.5
	3	512	0.0078125	77.3	74.1	80.6	79.2	75.7
	4	8192	0.00195312	72.5	58.3	86.6	81.4	67.5
1.16	1	2048	0.0078125	86.6	75.3	98.0	97.4	79.9
	2	128	0.03125	86.0	79.8	92.3	91.2	82.0
	3	32768	0.00195312	79.8	74.5	85.0	83.3	76.9
	4	512	0.03125	76.1	64.4	87.9	84.1	71.1
1.17	1	2048	0.125	89.3	85.4	93.1	92.5	86.5
	2	32768	0.00195312	83.2	82.6	83.8	83.6	82.8
	3	512	0.125	82.2	75.7	88.7	87.0	78.5
	4	32768	0.0078125	72.3	68.0	76.5	74.3	70.5
1.18	1	32768	0.0078125	84.0	84.2	83.8	83.9	84.1
	2	32768	0.00195312	87.0	83.8	90.3	89.6	84.8
	3	32768	0.000488281	79.1	75.7	82.6	81.3	77.3
	4	32768	0.000488281	73.9	64.0	83.8	79.8	69.9
1.19	1	32768	0.0078125	89.1	83.0	95.1	94.5	84.8
	2	8192	0.0078125	88.1	86.2	89.9	89.5	86.7
	3	128	0.125	79.4	72.1	86.6	84.4	75.6
	4	128	0.03125	74.1	58.7	89.5	84.8	68.4

Tabela B.8 Resultados da SVD a partir GLCM da imagem para θ fixo no intervalo $[0.1, 0.9]$

q	θ	C	γ	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
0.1	0°	32	2.0	66.2	72.5	59.9	64.4	68.5
	45°	128	0.5	60.7	55.9	65.6	61.9	59.8
	90°	128	0.125	63.0	39.3	86.6	74.6	58.8
	135°	2048	0.0078125	66.8	61.5	72.1	68.8	65.2
0.2	0°	2048	0.03125	68.6	65.6	71.7	69.8	67.6
	45°	2048	0.0078125	63.7	62.3	64.8	63.9	63.2
	90°	32768	0.00195312	66.4	66.0	66.8	66.5	66.3
	135°	32768	0.03125	62.6	62.3	62.8	62.6	62.5
0.3	0°	32768	0.000488281	73.1	64.8	81.4	77.7	69.8
	45°	512	0.03125	66.4	62.3	70.4	67.8	65.2
	90°	512	0.03125	67.8	74.1	61.5	65.8	70.4
	135°	2.0	8.0	60.9	55.9	66.0	62.2	59.9
0.4	0°	8192	0.00195312	73.9	70.9	76.9	75.4	72.5
	45°	128	0.03125	64.2	47.4	81.0	71.3	60.6
	90°	128	0.03125	65.8	66.0	65.6	65.7	65.9
	135°	32768	0.0078125	67.6	71.3	64.0	66.4	69.0
0.5	0°	32	0.5	77.1	74.9	79.4	78.4	76.0
	45°	512	0.00195312	66.6	50.2	83.0	74.7	62.5
	90°	32768	0.03125	59.3	58.7	59.9	59.4	59.2
	135°	128	0.03125	72.5	68.4	76.5	74.4	70.8
0.6	0°	32768	0.00012207	73.9	72.5	75.3	74.6	73.2
	45°	8192	0.00195312	71.5	68.4	74.5	72.8	70.2
	90°	512	0.0078125	73.5	67.2	79.8	76.9	70.9
	135°	8.0	0.5	70.9	75.3	66.4	69.1	72.9
0.7	0°	512	0.0078125	79.8	78.1	81.4	80.8	78.8
	45°	32768	0.00012207	71.7	62.3	81.0	76.6	68.3
	90°	512	0.03125	73.5	76.1	70.9	72.3	74.8
	135°	8192	0.00195312	73.9	68.8	78.9	76.6	71.7
0.8	0°	32	0.5	78.9	79.4	78.5	78.7	79.2
	45°	8.0	0.5	72.9	66.4	79.4	76.3	70.3
	90°	512	0.0078125	73.3	70.9	75.7	74.5	72.2
	135°	32	0.5	75.3	70.9	79.8	77.8	73.2
0.9	0°	32	2.0	76.5	76.1	76.9	76.7	76.3
	45°	512	0.125	71.7	71.7	71.7	71.7	71.7
	90°	512	0.03125	74.5	72.1	76.9	75.7	73.4
	135°	128	0.03125	78.1	74.9	81.4	80.1	76.4

Tabela B.9 Resultados da SVD a partir GLCM da imagem para θ fixo no intervalo $[1.1, 1.9]$

q	θ	C	γ	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.1	0°	128	0.03125	79.4	72.9	85.8	83.7	76.0
	45°	32768	0.00012207	72.7	62.3	83.0	78.6	68.8
	90°	32	8.0	69.8	73.7	66.0	68.4	71.5
	135°	8192	0.000195313	74.5	69.6	79.4	77.1	72.3
1.2	0°	32768	0.0078125	75.3	70.9	79.8	77.8	73.2
	45°	2048	0.0078125	72.3	77.7	66.8	70.1	75.0
	90°	8192	0.125	67.8	68.0	67.6	67.7	67.9
	135°	32768	0.00195312	70.2	72.9	67.6	69.2	71.4
1.3	0°	32	0.125	79.8	71.3	88.3	85.9	75.4
	45°	2048	0.03125	73.1	78.5	67.6	70.8	75.9
	90°	512	0.00195312	69.6	64.8	74.5	71.7	67.9
	135°	32768	0.000488281	73.9	79.4	68.4	71.5	76.8
1.4	0°	32	0.5	78.9	72.5	85.4	83.3	75.6
	45°	2048	0.03125	75.9	71.3	80.6	78.6	73.7
	90°	32	8.0	67.6	70.9	64.4	66.5	68.8
	135°	32	0.5	73.3	67.2	79.4	76.5	70.8
1.5	0°	32768	0.00195312	82.2	79.8	84.6	83.8	80.7
	45°	32768	0.000488281	75.9	73.3	78.5	77.4	74.6
	90°	8192	0.125	69.8	65.2	74.5	71.9	68.1
	135°	128	0.5	73.1	63.2	83.0	78.8	69.3
1.6	0°	8192	0.00195312	74.9	70.4	79.4	77.3	72.9
	45°	512	0.125	73.1	68.0	78.1	75.7	71.0
	90°	8.0	0.5	66.4	60.3	72.5	68.7	64.6
	135°	8192	0.03125	71.5	69.2	73.7	72.5	70.5
1.7	0°	8192	0.0078125	77.1	75.7	78.5	77.9	76.4
	45°	2048	0.0078125	74.5	74.5	74.5	74.5	74.5
	90°	8192	0.03125	78.5	81.4	75.7	77.0	80.3
	135°	2048	0.0078125	74.1	81.0	67.2	71.2	77.9
1.8	0°	2048	0.0078125	82.4	78.9	85.8	84.8	80.3
	45°	32768	0.00012207	76.9	74.5	79.4	78.3	75.7
	90°	32768	0.00012207	78.9	83.4	74.5	76.6	81.8
	135°	8.0	8.0	70.0	76.5	63.6	67.7	73.0
1.9	0°	2048	0.0078125	81.2	85.0	77.3	78.9	83.8
	45°	512	0.0078125	77.5	78.1	76.9	77.2	77.9
	90°	128	0.125	72.9	71.7	74.1	73.4	72.3
	135°	32768	0.00195312	75.3	77.3	73.3	74.3	76.4

Tabela B.10 Resultados da SVD a partir GLCM da imagem para θ fixo no intervalo $[1.81, 1.89]$

q	θ	C	γ	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.81	0°	128	0.125	80.8	75.3	86.2	84.5	77.7
	45°	8192	0.0078125	73.7	68.8	78.5	76.2	71.6
	90°	2048	0.00195312	73.1	63.6	82.6	78.5	69.4
	135°	2048	0.000195313	74.7	79.8	69.6	72.4	77.5
1.82	0°	32768	0.000488281	82.0	82.2	81.8	81.9	82.1
	45°	32768	0.000488281	78.3	74.1	82.6	81.0	76.1
	90°	32768	0.000488281	74.5	74.9	74.1	74.3	74.7
	135°	128	0.0078125	72.5	68.8	76.1	74.2	70.9
1.83	0°	128	0.125	79.4	69.6	89.1	86.4	74.6
	45°	8192	0.0078125	72.7	68.0	77.3	75.0	70.7
	90°	32	2.0	70.2	66.0	74.5	72.1	68.7
	135°	2048	0.03125	76.7	70.9	82.6	80.3	73.9
1.84	0°	8192	0.125	74.7	78.1	71.3	73.1	76.5
	45°	2048	0.00195312	74.3	70.0	78.5	76.5	72.4s
	90°	8192	0.03125	76.5	66.8	86.2	82.9	72.2
	135°	8192	0.0078125	74.9	65.6	84.2	80.6	71.0
1.85	0°	32768	0.0078125	78.5	78.9	78.1	78.3	78.8
	45°	512	0.03125	74.3	71.3	77.3	75.9	72.9
	90°	8.0	0.5	74.5	70.0	78.9	76.9	72.5
	135°	2048	0.03125	76.9	73.7	80.2	78.8	75.3
1.86	0°	512	0.5	78.5	81.4	75.7	77.0	80.3
	45°	512	0.03125	75.9	74.5	77.3	75.2	76.7
	90°	128	0.5	74.5	71.3	77.7	76.2	73.0
	135°	128	0.125	77.7	80.2	75.3	76.4	79.1
1.87	0°	32	0.5	83.8	82.2	85.4	84.9	82.7
	45°	8.0	0.5	72.0	72.9	71.3	71.7	72.4
	90°	8192	0.00195312	75.9	85.0	66.8	71.9	81.7
	135°	8192	0.03125	75.3	82.6	68.0	72.1	79.6
1.88	0°	32	0.5	84.4	85.4	83.4	83.7	85.1
	45°	2048	0.0078125	75.9	77.7	74.1	75.0	76.9
	90°	32	0.5	76.5	73.3	79.8	78.4	74.9
	135°	128	0.5	75.1	76.9	73.3	74.2	76.1
1.89	0°	8192	0.0078125	80.8	85.8	75.7	77.9	84.2
	45°	2048	0.03125	80.0	74.5	85.4	83.6	77.0
	90°	128	0.03125	77.9	76.1	79.8	79.0	77.0
	135°	8192	0.03125	72.1	64.8	79.4	75.8	69.3

Tabela B.11 Resultados da SVD a partir GLCM da imagem para d fixo no intervalo $[0.1, 0.9]$

q	θ	C	γ	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
0.1	1	32768	0.00195312	66.6	68.0	65.2	66.1	67.1
	2	2048	0.03125	59.9	59.1	60.7	60.1	59.8
	3	32	8.0	57.7	52.6	62.8	58.6	57.0
	4	32768	0.00195312	66.8	57.9	75.7	70.4	64.3
0.2	1	2048	0.0078125	70.6	67.2	74.1	72.1	69.3
	2	2048	0.125	65.4	61.9	68.8	66.5	64.4
	3	32768	0.0078125	65.4	59.5	71.3	67.4	63.8
	4	32768	0.000488281	65.2	64.8	65.6	65.3	65.1
0.3	1	512	0.03125	73.7	72.9	74.5	74.1	73.3
	2	8.0	0.03125	58.9	37.7	80.2	65.5	56.3
	3	8.0	2.0	61.9	68.4	55.5	60.6	63.7
	4	32768	0.00195312	65.6	57.9	73.3	68.4	63.5
0.4	1	512	0.03125	73.1	61.5	84.6	80.0	68.8
	2	128	0.5	66.4	64.8	68.0	66.9	65.9
	3	8.0	0.5	64.6	42.1	87.0	76.5	60.1
	4	32	2.0	60.9	46.2	75.7	65.5	58.4
0.5	1	8.0	0.5	68.8	66.8	70.9	69.6	68.1
	2	8192	0.00195312	69.0	59.5	78.5	73.5	66.0
	3	512	0.03125	66.6	66.8	66.4	66.5	66.7
	4	32768	0.00012207	65.6	54.7	76.5	69.9	62.8
0.6	1	32768	0.00012207	76.7	70.9	82.6	80.3	73.9
	2	2048	0.0078125	67.0	60.7	73.3	69.4	65.1
	3	0.03125	0.0078125	59.9	61.1	58.7	59.7	60.2
	4	512	0.0078125	67.8	50.6	85.0	77.2	63.3
0.7	1	128	0.03125	72.5	70.0	74.9	73.6	71.4
	2	32768	0.000488281	68.0	72.9	63.2	66.4	70.0
	3c	32	0.5	68.6	57.5	79.8	74.0	65.2
	4	2048	0.00012207	57.7	53.4	61.9	58.4	57.1
0.8	1	32768	0.000488281	75.7	72.1	79.4	77.7	74.0
	2	128	0.125	69.6	67.6	71.7	70.5	68.9
	3	2048	0.00012207	59.5	38.5	80.6	66.4	56.7
	4	32	2.0	62.3	59.5	65.2	63.1	61.7
0.9	1	8192	0.0078125	79.8	74.9	84.6	83.0	77.1
	2	32768	0.0078125	69.2	76.1	62.3	66.9	72.3
	3	2048	0.125	67.4	65.2	69.6	68.2	66.7
	4	32768	0.0078125	55.3	55.1	55.5	55.3	55.2

Tabela B.12 Resultados da SVD a partir GLCM da imagem para d fixo no intervalo $[1.1, 1.9]$

q	θ	C	γ	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.1	1	32768	0.000488281	79.8	77.3	82.2	81.3	78.4
	2	512	0.0078125	72.7	72.1	73.3	73.0	72.4
	3	2048	0.0078125	68.8	57.9	79.8	74.1	65.4
	4	512	0.0078125	68.0	57.1	78.9	73.1	64.8
1.2	1	128	0.5	76.1	73.7	78.5	77.4	74.9
	2	2048	0.0078125	71.1	66.8	75.3	73.0	69.4
	3	32768	0.03125	69.0	67.2	70.8	69.7	68.4
	4	2048	0.000488281	68.2	51.8	84.6	77.1	63.7
1.3	1	2048	0.0078125	76.9	69.6	84.2	81.5	73.5
	2	2048	0.03125	74.7	75.3	74.1	74.4	75.0
	3	2048	0.0078125	71.7	67.6	75.7	73.6	70.0
	4	2048	0.000488281	67.2	55.1	79.4	72.7	63.8
1.4	1	8192	0.03125	80.8	72.1	89.5	87.3	76.2
	2	2048	0.0078125	76.7	78.9	74.5	75.6	78.0
	3	128	0.03125	70.9	63.2	78.5	74.6	68.1
	4	2048	0.0078125	68.2	53.8	82.6	75.6	64.2
1.5	1	512	0.125	82.0	75.3	88.7	86.9	78.2
	2	8.0	2.0	70.6	65.6	75.7	73.0	68.8
	3	32768	0.03125	73.7	74.1	73.3	73.5	73.9
	4	2048	0.0078125	68.4	64.0	72.9	70.2	66.9
1.6	1	2048	0.03125	79.1	72.9	85.4	83.3	75.9
	2	128	0.5	75.3	66.0	84.6	81.1	71.3
	3	2048	0.03125	73.9	72.1	75.7	74.8	73.0
	4	32768	0.0078125	65.8	61.9	69.6	67.1	64.7
1.7	1	32768	0.0078125	82.0	75.7	88.3	86.6	78.4
	2	128	0.125	71.3	72.1	70.4	70.9	71.6
	3	32	0.5	73.9	68.4	79.4	76.8	71.5
	4	2048	0.0078125	72.7	67.2	78.1	75.5	70.4
1.8	1	32768	0.0078125	80.8	79.8	81.8	81.4	80.2
	2	32	0.5	76.1	75.7	76.5	76.3	75.9
	3	32	0.5	70.2	74.9	65.6	68.5	72.3
	4	32768	0.000488281	64.4	65.6	63.2	64.0	64.7
1.9	1	2048	0.0078125	80.2	80.2	80.2	80.2	80.2
	2	8192	0.125	75.7	68.0	83.4	80.4	72.3
	3	128	0.5	67.8	68.0	67.6	67.7	67.9
	4	512	0.03125	67.8	61.1	74.5	70.6	65.7

Tabela B.13 Resultados da SVD a partir GLCM da imagem para d fixo no intervalo $[1.71, 1.79]$

q	θ	C	γ	Estatísticas (%)				
				Acur.	**Sens.**	**Espec.**	**VPP**	**VPN**
1.71	1	2048	0.03125	81.4	80.6	82.2	81.9	80.9
	2	8192	0.03125	74.5	69.6	79.4	77.1	72.3
	3	2048	0.03125	72.1	72.5	71.7	71.9	72.2
	4	32768	0.000488281	68.4	59.5	77.3	72.4	65.6
1.72	1	8192	0.00195312	81.2	76.9	85.4	84.1	78.7
	2	2048	0.03125	75.7	70.0	81.4	79.0	73.1
	3	32768	0.00195312	73.1	73.3	72.9	73.0	73.2
	4	8.0	2.0	62.6	64.0	61.1	62.2	62.9
1.73	1	32768	0.00195312	82.0	79.4	84.6	83.8	80.4
	2	32768	0.00195312	74.5	71.3	77.7	76.2	73.0
	3	512	0.125	71.9	69.2	74.5	73.1	70.8
	4	32768	0.0078125	66.0	68.4	63.6	65.3	66.8
1.74	1	32768	0.00012207	78.7	78.1	79.4	79.1	78.4
	2	2048	0.0078125	78.1	76.9	79.4	78.8	77.5
	3	32768	0.00012207	72.1	68.8	75.3	73.6	70.7
	4	2048	0.0078125	65.0	64.0	66.0	65.3	64.7
1.75	1	2048	0.0078125	73.1	64.0	82.2	78.2	69.5
	2	32768	0.00195312	75.1	74.9	75.3	75.2	75.0
	3	128	0.125	74.1	71.7	76.5	75.3	73.0
	4	8.0	8.0	63.8	56.3	71.3	66.2	62.0
1.76	1	32768	0.0078125	84.2	79.8	88.7	87.6	81.4
	2	2048	0.0078125	78.1	78.1	78.1	78.1	78.1
	3	128	0.125	69.2	74.1	64.4	67.5	71.3
	4	32768	0.000488281	68.8	64.8	72.9	70.5	67.4
1.77	1	2048	0.03125	80.0	79.8	80.2	80.1	79.8
	2	128	0.5	72.3	67.6	76.9	74.6	79.4
	3	2048	0.125	71.5	71.3	71.7	71.5	71.4
	4	128	0.5	65.8	56.3	75.3	69.5	63.3
1.78	1	8192	0.125	74.1	73.7	74.5	74.3	73.9
	2	8192	0.125	72.5	66.0	78.9	75.8	69.9
	3	512	0.0078125	68.4	72.1	64.8	67.2	69.9
	4	32768	0.0000305176	63.2	58.7	67.6	64.4	62.1
1.79	1	2048	0.0078125	82.6	74.5	90.7	88.9	78.0
	2	2048	0.5	69.2	75.7	62.8	67.0	72.1
	3	2048	0.03125	70.2	57.5	83.0	77.2	66.1
	4	32	2.0	63.2	55.1	71.3	65.7	61.3

REFERÊNCIAS BIBLIOGRÁFICAS

ALBUQUERQUE, M. P. de et al. Image thresholding using tsallis entropy. *Pattern Recognition Letters*, v. 25, n. 9, p. 1059 – 1065, 2004. ISSN 0167-8655. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0167865504000698>.

ALBUQUERQUE, M. P. de et al. Image thresholding using tsallis entropy. *Pattern Recognition Letters*, v. 25, n. 9, p. 1059 – 1065, 2004.

ANDREWS, H.; PATTERSON, C. Singular value decompositions and digital image processing. *Acoustics, Speech and Signal Processing, IEEE Transactions on*, v. 24, n. 1, p. 26–53, Feb 1976. ISSN 0096-3518.

BARTH, R. J.; GIBSON, G. R. Detection of breast cancer on screening mammography allows patients to be treated with less-toxic therapy. *American Journal of Roentgenology*, n. 184, p. 324–329, 2005.

BATEMAN, A. C. Pathology of breast cancer. *Women's Health Medicine*, v. 3, n. 1, p. 18 – 21, 2006. ISSN 1744-1870. Breast disorders. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1744187006001193>.

BIGLIERI, E.; YAO, K. Some properties of singular value decomposition and their applications to digital signal processing. *Signal Processing*, v. 18, n. 3, p. 277 – 289, 1989. ISSN 0165-1684. Disponível em: <http://www.sciencedirect.com/science/article/pii/016516848990039X>.

BISHOP, C. *Pattern Recognition and Machine Learning*. Springer, 2006. (Information Science and Statistics). ISBN 9780387310732. Disponível em: <https://books.google.com.br/books?id=kTNoQgAACAAJ>.

CANCER, I. N. do. 2014. Disponível em: <http://www.inca.gov.br>.

CARNEY, P. A. et al. Individual and combined effects of age, breast density, and hormone replacement therapy use on the accuracy of screening mammography. *Annals of Internal Medicine*, v. 138, n. 3, p. 168–175, 2003. Disponível em: <+http://dx.doi.org/10.7326/0003-4819-138-3-200302040-00008>.

CHANG, C.-C.; LIN, C.-J. LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, v. 2, p. 27:1–27:27, 2011. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.

CHENG, H. et al. Computer-aided detection and classification of microcalcifications in mammograms: a survey. *Pattern Recognition*, v. 36, n. 12, p. 2967 – 2991, 2003. ISSN 0031-3203. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0031320303001924>.

COX, R. F.; MORGAN, M. P. Microcalcifications in breast cancer: Lessons from physiological mineralization. *Bone*, v. 53, n. 2, p. 437 – 450, 2013. ISSN 8756-3282. Disponível em: <http://www.sciencedirect.com/science/article/pii/S8756328213000203>.

DANTAS, R. et al. MÉtodo svd: AnÁlise wavelets-mÃe na extraÇÃo de textura aplicadas em mamogramas. v. 1, n. 1, 2011.

DOI, K. Computer-aided diagnosis in medical imaging: Achievements and challenges. In: DöSSEL, O.; SCHLEGEL, W. (Ed.). *World Congress on Medical Physics and Biomedical Engineering, September 7 - 12, 2009, Munich, Germany*. Springer Berlin Heidelberg, 2009, (IFMBE Proceedings, v. 25/5). p. 96–96. ISBN 978-3-642-03903-4. Disponível em: <http://dx.doi.org/10.1007/978-3-642-03904-1_26>.

DRUKTEINIS, J. S. et al. Beyond mammography: New frontiers in breast cancer screening. *The American Journal of Medicine*, v. 126, n. 6, p. 472 – 479, 2013. ISSN 0002-9343. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0002934313000910>.

DW POLLOCK RE, W. R. K. *Holland-Frei Cancer Medicine*. 6. ed. BC Decker, 2003. Disponível em: <http://www.ncbi.nlm.nih.gov/books/NBK12354/>.

ECONOMOPOULOU, P.; DIMITRIADIS, G.; PSYRRI, A. Beyond brca: New hereditary breast cancer susceptibility genes. *Cancer Treatment Reviews*, v. 41, n. 1, p. 1 – 8, 2015. ISSN 0305-7372. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0305737214001741>.

EL-NAQA, I. et al. A support vector machine approach for detection of microcalcifications. *Medical Imaging, IEEE Transactions on*, v. 21, n. 12, p. 1552–1563, Dec 2002. ISSN 0278-0062.

ELEYAN, A.; DEMİREL, H. Co-occurrence matrix and its statistical features as a new approach for face recognition. *Turkish Journal of Electrical Engineering and Computer Sciences*, v. 19, n. 1, p. 97 – 107, 2011. ISSN 13000632.

ELLIS, H.; MAHADEVAN, V. Anatomy and physiology of the breast. *Surgery (Oxford)*, v. 31, n. 1, p. 11 – 14, 2013. ISSN 0263-9319. Breast. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0263931912002347>.

FREEMAN, H. Computer processing of line-drawing images. *ACM Comput. Surv.*, ACM, New York, NY, USA, v. 6, n. 1, p. 57–97, mar. 1974. ISSN 0360-0300. Disponível em: <http://doi.acm.org/10.1145/356625.356627>.

GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing (2nd Edition)*. [S.l.]: Pearson, 2002.

GORDON, R.; RANGAYYAN, R. M. Feature enhancement of film mammograms using fixed and adaptive neighborhoods. v. 23, p. 560–564, Feb 1984.

HARALICK, R.; SHANMUGAM, K.; DINSTEIN, I. Textural features for image classification. *Systems, Man and Cybernetics, IEEE Transactions on*, SMC-3, n. 6, p. 610–621, Nov 1973. ISSN 0018-9472.

HEATH, M. Current status of the digital database for screening mammography. *Proceedings of the Fourth International Workshop on Digital Mammography*, 1998.

HUFFMAN, D. A. A method for the construction of minimum-redundancy codes. *Proceedings of the Institute of Radio Engineers*, v. 40, n. 9, p. 1098–1101, September 1952.

International Agency for Research on Cancer. *IARC - INTERNATIONAL AGENCY FOR RESEARCH ON CANCER*. 2012. <http://www.iarc.fr/en/about/index.php>. Acessado em 10 de Janeiro 2014.

JALALIAN, A. et al. Computer-aided detection/diagnosis of breast cancer in mammography and ultrasound: a review. *Clinical Imaging*, v. 37, n. 3, p. 420 – 426, 2013. ISSN 0899-7071. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0899707112002938>.

JESINGER, R. A. Breast anatomy for the interventionalist. *Techniques in Vascular and Interventional Radiology*, v. 17, n. 1, p. 3 – 9, 2014. ISSN 1089-2516. Breast Interventions. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1089251613000887>.

KARSSEMEIJER, N.; BRAKE, G. te. Detection of stellate distortions in mammograms. *Medical Imaging, IEEE Transactions on*, v. 15, n. 5, p. 611–619, Oct 1996. ISSN 0278-0062.

KHUZI, A. M. et al. Identification of masses in digital mammogram using gray level co-occurrence matrices. *Biomed Imaging Interv J*, Department of Biomedical Imaging, Faculty of Medicine, University of Malaya, Malaysia, v. 5, n. 3, p. 17, 2009. ISSN 1823-5530. 21611053[pmid]. Disponível em: <http://www.ncbi.nlm.nih.gov/pmc/articles/PMC3097782/>.

KOBATAKE, H. et al. Computerized detection of malignant tumors on digital mammograms. *Medical Imaging, IEEE Transactions on*, v. 18, n. 5, p. 369–378, May 1999. ISSN 0278-0062.

KUPINSKI, M.; GIGER, M. Investigation of regularized neural networks for the computerized detection of mass lesions in digital mammograms. In: *Engineering in Medicine and Biology Society, 1997. Proceedings of the 19th Annual International Conference of the IEEE*. [S.l.: s.n.], 1997. v. 3, p. 1336–1339 vol.3. ISSN 1094-687X.

LI, H. et al. Markov random field for tumor detection in digital mammography. *Medical Imaging, IEEE Transactions on*, v. 14, n. 3, p. 565–576, Sep 1995. ISSN 0278-0062.

LI, L.; CLARK, R. A.; THOMAS, J. A. Computer-aided diagnosis of masses with full-field digital mammography. *Academic Radiology*, v. 9, n. 1, p. 4 – 12, 2001. ISSN 1076-6332. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1076633203802908>.

LIU, S.; BABBS, C.; DELP, E. Multiresolution detection of spiculated lesions in digital mammograms. *Image Processing, IEEE Transactions on*, v. 10, n. 6, p. 874–884, Jun 2001. ISSN 1057-7149.

LIU, Y. K.; ŽALIK, B. An efficient chain code with huffman coding. *Pattern Recognition*, v. 38, n. 4, p. 553 – 557, 2005. ISSN 0031-3203. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0031320304003723>.

MOHANALIN et al. A novel automatic microcalcification detection technique using tsallis entropy and a type ii fuzzy index. *Computers and Mathematics with Applications*, v. 60, n. 8, p. 2426 – 2432, 2010. ISSN 0898-1221. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0898122110006024>.

MUDIGONDA, N.; RANGAYYAN, R.; DESAUTELS, J. Gradient and texture analysis for the classification of mammographic masses. *Medical Imaging, IEEE Transactions on*, v. 19, n. 10, p. 1032–1043, Oct 2000. ISSN 0278-0062.

NITHYA, R.; SANTHI, B. Classification of normal and abnormal patterns in digital mammograms for diagnosis of breast cancer. *International Journal of Computer Applications*, v. 28, n. 6, p. 21–25, August 2011. Full text available.

NITHYA, R.; SANTHI, B. Comparative study on feature extraction method for breast cancer classification. *Journal of Theorical and Applied Information Technology*, v. 33, n. 2, November 2011.

NITHYA, R.; SANTHI, B. Mammogram classification using maximum difference feature selection method. *Journal of Theorical and Applied Information Technology*, v. 33, n. 2, November 2011.

NOKIA. *Qt Project*. 2015. Disponível em: <https://qt-project.org/>.

OTSU, N. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man and Cybernetics*, v. 9, n. 1, p. 62–66, Jan 1979. ISSN 0018-9472.

PARKER, J. *Algorithms for Image Processing and Computer Vision*. Wiley, 2010. (IT Pro). ISBN 9781118021880. Disponível em: <https://books.google.com.br/books?id=BK3oXzpxC44C>.

PRATIWI, M. et al. Mammograms classification using gray-level co-occurrence matrix and radial basis function neural network. *Procedia Computer Science*, v. 59, p. 83 – 91, 2015. International Conference on Computer Science and Computational Intelligence (ICCSCI 2015). Disponível em: <http://www.sciencedirect.com/science/article/pii/S1877050915018694>.

RADIOLOGY, A. C. of. 2014. Disponível em: <http://www.acr.org/>.

SADEK, A. SVD Based Image Processing Applications: State of The Art, Contributions and Research Challenges. *ArXiv e-prints*, nov. 2012.

SADEK, R. A. SVD Based Image Processing Applications: State of The Art, Contributions and Research Challenges. nov 2012. Disponível em: <http://arxiv.org/abs/1211.7102>.

SAMPAT, M. P.; MARKEY, M. K.; BOVIK, A. C. Computer-aided detection and diagnosis in mammography. In: BOVIK, A. (Ed.). *Handbook of Image and Video Processing (Second Edition)*. 2. ed. Burlington: Academic Press, 2005, (Communications, Networking and Multimedia). p. 1195 – 1217. ISBN 978-0-12-119792-6. Disponível em: <http://www.sciencedirect.com/science/article/pii/B9780121197926501303>.

SANDERSON, C. *Armadillo: An Open Source C++ Linear Algebra Library for Fast Prototyping and Computationally Intensive Experiments*. Australia, 2010.

STEINBRUCH, A.; WINTERLE, P. *Introdução à algebra linear*. McGraw-Hill Medical, 1990. ISBN 9780074609446. Disponível em: <https://books.google.com.br/books?id=SPK5PgAACAAJ>.

STRANG, G. *Linear Algebra and Its Applications*. Thomson Brooks/Cole, 2006. ISBN 9780534422004. Disponível em: <http://books.google.com.br/books?id=q9CaAAAACAAJ>.

STRICKLAND, R.; HAHN, H. I. Wavelet transforms for detecting microcalcifications in mammograms. *Medical Imaging, IEEE Transactions on*, v. 15, n. 2, p. 218–229, Apr 1996. ISSN 0278-0062.

SUCKLING J. PARKER, D. R. D. J. The mammographic image analysis society digital mammogram database. *2nd International Workshop on Digital Mammography*, p. 375–378, 1994.

TECHNOLOGY, S. 2015. Disponível em: <http://www.servimedic.com.br/para-pacientes/mamoplastia-de-aumento/?s=7|anatomia>.

TOURASSI, G. D. et al. Computer-assisted detection of mammographic masses: A template matching scheme based on mutual information. *Medical Physics*, v. 30, n. 8, p. 2123–2130, 2003. Disponível em: <http://scitation.aip.org/content/aapm/journal/medphys/30/8/10.1118/1.1589494>.

Tsallis, C. Possible generalization of Boltzmann-Gibbs statistics. *Journal of Statistical Physics*, v. 52, p. 479–487, jul. 1988.

TUPPER, R.; HOLM, K. Screening mammography and breast cancer reduction: Examining the evidence. *The Journal for Nurse Practitioners*, v. 10, n. 9, p. 721 – 728, 2014. ISSN 1555-4155. Special Focus: Legal Matters. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1555415514005042>.

VIEIRA, C. S. *Oncologia Básica*. 1. ed. [S.l.]: Fundação Quixote, 2012.

VIRMANI, J. et al. Svm-based characterisation of liver cirrhosis by singular value decomposition of glcm matrix. *Int. J. Artif. Intell. Soft Comput.*, Inderscience Publishers, Inderscience Publishers, Geneva, SWITZERLAND, v. 3, n. 3, p. 276–296, abr. 2013. ISSN 1755-4950. Disponível em: <http://dx.doi.org/10.1504/IJAISC.2013.053407>.

WANG, H. et al. Mammography visual enhancement in cad-based breast cancer diagnosis. *Clinical Imaging*, v. 37, n. 2, p. 273 – 282, 2013. ISSN 0899-7071. Disponível em: <http://www.sciencedirect.com/science/article/pii/S089970711200157X>.