

Geovane Menezes Ramos Neto

**Estudo de Variantes de Padrões Locais Binários
para o Diagnóstico de Câncer de Mama**

São Luís - MA

2016

Geovane Menezes Ramos Neto

Estudo de Variantes de Padrões Locais Binários para o Diagnóstico de Câncer de Mama

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação.

Universidade Federal do Maranhão
Centro de Ciências Exatas e Tecnológicas
Curso de Ciência da Computação

Orientador: Prof. Dr. Geraldo Braz Junior

São Luís - MA

2016

Ramos Neto, Geovane Menezes

Estudo de Variantes de Padrões Locais Binários para o diagnóstico de Câncer de mama/
Geovane Menezes Ramos Neto. – São Luis, 2016.

44f.

Orientador: Geraldo Braz Jr

Monografia (Graduação) – Universidade Federal do Maranhão, Curso de Ciência da
Computação, 2016.

1. Câncer de Mama 2. Padrões Locais Binários 3. Diagnóstico de Câncer 4. Análise
de Textura

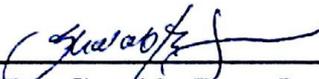
CDU 004.383.5:616-006

Geovane Menezes Ramos Neto

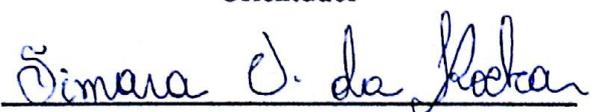
Estudo de Variantes de Padrões Locais Binários para o Diagnóstico de Câncer de Mama

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação.

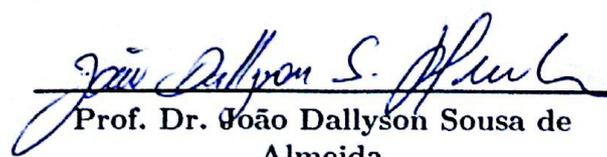
Trabalho Aprovado Nota 10,0. São Luís - MA, 04 de 03 de 2016:



Prof. Dr. Geraldo Braz Junior
Orientador



Prof. Dra. Simara Vieira da Rocha
Examinador 1



Prof. Dr. João Dallyson Sousa de Almeida
Examinador 2

São Luís - MA
2016

Resumo

O câncer de mama é o tipo de câncer que mais acomete as mulheres em todo o mundo. Cerca de 57.120 novos casos dessa neoplasia foram esperados para o ano de 2015 no Brasil (INCA, 2015). Quanto mais precoce o diagnóstico do câncer, maiores são as chances que o tratamento seja bem sucedido. O diagnóstico do câncer de mama através da mamografia depende bastante do especialista, pois este varia de acordo com a idade do paciente, qualidade da imagem obtida e experiência do especialista.

Este estudo utiliza técnicas de processamento digital de imagens para discriminar os padrões de massas malignas e benignas. Esta discriminação se dá através da utilização de operadores locais, buscando caracterizar as texturas utilizando os histograma extraído a partir da aplicação das técnicas *Local Binary Pattern*, *Local Quinary Pattern*, *Circular-Symmetric Local Binary Pattern* e *Compound Local Binary Pattern*, além de combinar cada uma das técnicas com as abordagens *Cartesian Grid*, *Grid X*, *Complete Grid*, Abordagem Circular e a Abordagem Elíptica. Por fim, a textura será classificada utilizando a Máquina de Vetores de Suporte. O melhor resultado foi obtido utilizando a técnica *Compound Local Binary Pattern* com a abordagem *Cartesian Grid*, obtendo 89,09% de Acurácia, 84,00% de Sensibilidade, 95,09% de Especificidade e F-Score de 0,8929.

Palavras-chave: Câncer de Mama. Padrões Locais Binários. Diagnóstico de Câncer. Análise de Textura.

Abstract

Breast cancer is the type of cancer that affects more women worldwide, both in developing countries as in developed countries. About 57,120 new cases of this cancer were expected for the year 2015 in Brazil (INCA, 2015). The earlier cancer diagnosis, the better the chances that treatment will be successful. The diagnosis of breast cancer through mammography depends greatly on the expert, as this varies depending on the patient's age, obtained image quality and experience of the expert.

This study uses digital image processing techniques to discriminate patterns of benign and malignant masses. This discrimination is through the use of local operators, seeking to characterize the textures using the extracted histogram from the application of techniques Local Binary Pattern, Local quinary Pattern, Circular-Symmetric Local Binary Pattern and Compound Local Binary Pattern, and combine each of the techniques with approaches Cartesian Grid, Grid X, Complete Grid, Circular approach and Elliptical approach. Finally, the texture is classified using a support vector machine. The best result was obtained using the technique Compound Local Binary Pattern with Cartesian Grid approach, obtaining 89.09% of Accuracy, 84.00% Sensitivity, 95.09% Specificity and F-Score of 0.8929.

Keywords: Breast Cancer. Local Binary Patterns. Diagnosis of Cancer. Texture Analysis.

Lista de ilustrações

Figura 1 – Vizinhanças circularmente simétricas para diferentes valores de P e R . Fonte: Retirado de (OJALA; PIETIKÄINEN; MÄENPÄÄ, 2002).	18
Figura 2 – Cálculo do LBP. (a) A imagem; (b) A imagem binária; (c) Matriz de Pesos; (d) Valores resultantes. Fonte: Retirado de (ROCHA, 2014).	19
Figura 3 – Um exemplo da divisão do código LQP em quatro códigos LBP. Fonte: Retirado de (NANNI; LUMINI; BRAHNAM, 2012).	20
Figura 4 – Exemplo da diferença entre o cálculo do LBP e do CS-LBP em uma vizinhança de 8 pixels, onde $s(x)$ é uma função que devolve 1 se $x \geq 0$ ou 0, caso contrario. Retirado de (HEIKKILÄ; PIETIKÄINEN; SCHMID, 2006).	21
Figura 5 – Geração dos códigos sub-CLBP a partir do código original do CLBP. Retirado de (AHMED et al., 2011).	22
Figura 6 – Separação de duas classes através de duas classes de hiperplanos. Fonte: Retirado de (ROCHA, 2014).	23
Figura 7 – Vetores de Suporte para determinação do hiperplano de separação (destacados por círculos). Fonte: Retirado de (ROCHA, 2014).	24
Figura 8 – Representação da metodologia deste estudo	26
Figura 9 – A Figura (a) representa uma lesão benigna a Figura (b) representa uma lesão maligna	27
Figura 10 – Exemplos de <i>Cartesian Grid</i> . Em (a) 2x2, em (b) 4x4 e em (c) e (d) exemplos das ROIs resultantes.	28
Figura 11 – Exemplo de <i>Grid X</i>	28
Figura 12 – Exemplo de <i>Complete Grid</i>	29
Figura 13 – Exemplo da abordagem circular.	29
Figura 14 – Exemplo da abordagem dos anéis circulares.	29
Figura 15 – Exemplo da abordagem elíptica.	30
Figura 16 – Exemplo da abordagem dos anéis elípticos	30
Figura 17 – Fluxo da metodologia para reconhecimento de padrões.	32
Figura 18 – Gráfico das médias da F-Score utilizando os histogramas para cada uma das técnicas de acordo com a porcentagem de treino utilizada.	34
Figura 19 – Gráfico da F-Score da <i>grid 2x2</i> para cada uma das técnicas de acordo com a porcentagem de treino utilizada.	35
Figura 20 – Gráfico da F-Score da <i>grid 4x4</i> para cada uma das técnicas de acordo com a porcentagem de treino utilizada.	35
Figura 21 – Gráfico da F-Score da <i>Grid X</i> para cada uma das técnicas de acordo com a porcentagem de treino utilizada.	36

Figura 22 – Gráfico da F-Score da <i>Complete Grid</i> para cada uma das técnicas de acordo com a porcentagem de treino utilizada.	37
Figura 23 – Gráfico da F-Score da abordagem Circulares para cada uma das técnicas de acordo com a porcentagem de treino utilizada.	37
Figura 24 – Gráfico da F-Score da abordagem Anéis Circulares para cada uma das técnicas de acordo com a porcentagem de treino utilizada.	38
Figura 25 – Gráfico da F-Score da abordagem Elíptica para cada uma das técnicas de acordo com a porcentagem de treino utilizada.	39
Figura 26 – Gráfico da F-Score da abordagem Anéis Elípticos para cada uma das técnicas de acordo com a porcentagem de treino utilizada.	39

Lista de tabelas

Tabela 1 – Quantidade de características geradas para cada par abordagem/técnica	31
Tabela 2 – Exemplo de matriz de confusão	33
Tabela 3 – Quadro da melhor técnica (CLBP) juntamente com as 3 melhores abordagens, mostrando todas as informações estatísticas relevantes. . .	40

Lista de abreviaturas e siglas

WCR	World Cancer Report
IARC	International Agency for Research on Cancer
OMS	Organização Mundial da Saúde
INCA	Instituto Nacional de Câncer
CADe	Computer-aided Detection
CADx	Computer-aided Diagnosis
LBP	Local Binary Pattern
LQP	Local Quinary Pattern
CS-LBP	Center-Symmetric Local Binary Pattern
CLBP	Compound Local Binary Pattern
MVS	Máquina de Vetores de Suporte
DDSM	Digital Database for Screening Mammography
ROI	Region Of Interest

Sumário

1	INTRODUÇÃO	12
1.0.1	O diagnóstico do câncer através de técnicas computacionais	14
1.1	Objetivo	15
1.1.1	Objetivos Específicos	15
1.2	Contribuições	15
1.3	Organização da Monografia	16
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	O processamento digital de imagens	17
2.2	Descritores de Textura	17
2.3	Local Binary Pattern (LBP)	18
2.4	Local Quinary Pattern (LQP)	19
2.5	Center-Symmetric Local Binary Pattern (CS-LBP)	20
2.6	Compound Local Binary Pattern (CLBP)	21
2.7	Máquina de Vetores de Suporte	22
3	METODOLOGIA	26
3.1	Aquisição de Imagens	26
3.2	Decomposição Espacial	27
3.3	Extração de Características	30
3.4	Reconhecimento de Padrões	31
3.5	Validação dos Resultados	32
4	RESULTADOS	34
4.1	Histograma	34
4.2	Abordagem <i>Cartesian Grid</i>	35
4.3	Abordagem <i>Grid X</i>	36
4.4	Abordagem <i>Complete Grid</i>	36
4.5	Abordagem Circular	37
4.6	Abordagem Elíptica	38
4.7	Quadro Geral dos Resultados	39
5	CONCLUSÃO	41
5.1	Trabalhos Futuros	41

REFERÊNCIAS	42
--------------------------	-----------

1 Introdução

O câncer é caro, juntamente com o custo monetário há o custo humano, que inclui a incerteza e o sofrimento que um diagnóstico de câncer possui. Por trás de cada estatística há um indivíduo, acompanhado por seus familiares e amigos que juntos sofrem juntos deste mal.

Segundo a World Cancer Report (WCR) (STEWART; WILD et al., 2014), a incidência de câncer aumentou de 12,7 milhões em 2008 para 14,1 milhões em 2012, essa tendência de crescimento deverá continuar, aumentando o número de novos casos em aproximadamente 75%. Isto trará o número de casos de câncer próximo a 25 milhões nas próximas duas décadas. Inquestionavelmente o maior impacto será em países de baixa e média renda, muitos dos quais são mal equipados para lidar com essa grande quantidade de casos de câncer.

Não são apenas os novos casos de câncer de mama que crescem, a taxa de mortalidade do câncer no mundo deverá ter um aumento esperado de 8,2 milhões em 2012 para 14,6 milhões em 2035 (STEWART; WILD et al., 2014). Esta estatística dá uma ideia do quão grave é a situação atual do câncer no mundo, e que medidas de prevenção, detecção e diagnóstico do câncer devem ter um foco maior nas próximas décadas. Em países menos desenvolvidos o câncer é tipicamente diagnosticado em estágios avançados da doença, além do tratamento efetivo da doença ser limitado e, algumas vezes inexistente, indicando onde o controle do câncer deve ser mais incisivo e atuante.

A carga de câncer continuará aumentando em países em desenvolvimento e crescerá ainda mais em países desenvolvidos se medidas preventivas não forem amplamente aplicadas. As estimativas mundiais do projeto Globocan 2012, da Agência Internacional para Pesquisa em Câncer (IARC, do inglês International Agency for Research on Cancer), da Organização Mundial da Saúde (OMS) informam que em países desenvolvidos, os tipos de câncer mais frequentes na população masculina foram próstata, pulmão e cólon e reto; na população feminina os tipos mais frequentes são mama, cólon e reto e pulmão. Nos países em desenvolvimento, os três tipos de câncer mais frequentes em homens foram pulmão, estômago e fígado; e mama, colo do útero e pulmão nas mulheres.

Entre os homens, os cinco tipos de câncer mais diagnosticados em 2012 foram os de pulmão (16,7% do total), da próstata (15,0%), colórectum (10,0%), do estômago (8,5%), e do fígado (7,5%). Estes locais também representam as causas mais comuns de morte por câncer em homens; a importância relativa do câncer de pulmão aumentou para 23,6% do total, seguido de câncer do fígado (11,2%) e câncer no estômago (10,1%) como segunda e terceira causas mais comuns de morte por câncer (STEWART; WILD et al., 2014).

Estimativas para o ano de 2014, que também são válidas para o ano de 2015 para o Brasil apontam a ocorrência de aproximadamente 576 mil novos casos de câncer, incluindo casos de câncer de pele não melanoma, reforçando a magnitude do problema do câncer no país. O câncer de pele não melanoma (182 mil novos casos) será o mais incidente na população brasileira, seguido pelos tumores de próstata (69 mil), mama feminina (57 mil), cólon e reto (33 mil), pulmão (27 mil), estômago (20 mil) e colo do útero (15 mil) (INCA, 2014).

De acordo com o INCA (INCA, 2014) se não forem considerados os casos de câncer de pele não melanoma, estimam-se 395 mil casos novos de câncer, 204 mil para o sexo masculino e 190 mil para sexo feminino em todo o Brasil. Na população masculina, os tipos mais incidentes serão os cânceres de próstata, pulmão, cólon e reto, estômago e cavidade oral; e, na população feminina, os de mama, cólon e reto, colo do útero, pulmão e glândula tireoide. É incontestável que o câncer é hoje, no Brasil, um problema de saúde pública, cujos controle e prevenção deverão ser priorizados em todas as regiões, desde as mais desenvolvidas – cultural, social e economicamente – até às mais desiguais.

Do ponto de vista dos cientistas do genoma, o câncer é uma doença no genoma. Todos os cânceres partem de mutações no seu genoma. Algumas destas mutações têm efeitos profundos na biologia do célula cancerosa dirigindo o crescimento do tumor. Algumas mutações podem desativar genes que geralmente protegem as células da proliferação anormal; estes são classicamente referidos como genes supressores de tumor. Outras mutações podem resultar em proteínas com funções oncogênicas que estimulam o crescimento celular ou fornecem outras vantagens para as células cancerosas, afetando assim as vias biológicas envolvidas na transformação de células normais em células cancerosas (STEWART; WILD et al., 2014).

O câncer de mama é o tipo de câncer que mais acomete as mulheres em todo o mundo, tanto em países em desenvolvimento quanto em países desenvolvidos. Cerca de 57.120 novos casos dessa neoplasia foram esperados para o ano de 2015 no Brasil (INCA, 2015). Suas taxas de incidência variam entre as diferentes regiões do mundo, com as maiores taxas em 2012 na Europa Ocidental (96/ 100 mil) e as menores taxas na África Central e na Ásia Oriental (27/ 100 mil) (INCA, 2014).

Em 2015, no Brasil, foram esperados 57.120 novos casos de câncer de mama, com um risco estimado de 56,09 casos a cada 100 mil mulheres. Desconsiderando os tumores de pele não melanoma, esse tipo de câncer é o tipo mais frequente de câncer em mulheres nas regiões Sudeste (71,18/ 100 mil), Sul (70,98/ 100 mil), Centro-Oeste (51,30/ 100 mil) e Nordeste (36,74/ 100 mil). Na região Norte, é o segundo tumor mais incidente (21,29/ 100 mil) (INCA, 2014).

O câncer de mama é a maior causa de morte por câncer nas mulheres em todo o mundo, com cerca de 520 mil mortes estimadas para o ano de 2012. É a segunda causa

de morte por câncer nos países desenvolvidos, atrás somente do câncer de pulmão, e a maior causa de morte por câncer nos países em desenvolvimento. Segundo a (ACS, 2015) aproximadamente 40.290 mortes causadas pelo câncer de mama.

1.0.1 O diagnóstico do câncer através de técnicas computacionais

No Brasil, a mamografia bienal para mulheres entre 50 a 69 anos e o exame clínico das mamas anualmente a partir dos 40 anos é a estratégia recomendada para a detecção precoce do câncer de mama em mulheres com risco padrão. Para as mulheres de grupos populacionais considerados de risco elevado para câncer de mama (com história familiar de câncer de mama em parentes de primeiro grau), recomenda-se o exame clínico da mama e a mamografia, anualmente, a partir de 35 anos (INCA, 2014).

Apesar de ser considerado um câncer de um relativo bom prognóstico, se diagnosticado e tratado oportunamente, as taxas de mortalidade por câncer de mama continuam elevadas no Brasil, muito provavelmente porque a doença ainda é diagnosticada em estágios avançados. A sobrevida em um, cinco, dez e vinte anos, em países desenvolvidos, como a Inglaterra é de 95,8%, 85,1%, 77% e 64% respectivamente. O estudo do INCA, apresentou, para o câncer de mama, uma sobrevida de aproximadamente 80% (INCA, 2014).

Entendendo a importância do diagnóstico precoce para um bom prognóstico do câncer de mama, técnicas de processamento digital de imagens foram desenvolvidas com o intuito de melhorar as técnicas de diagnóstico já existentes. Existem dois tipos de ferramentas que utilizam de técnicas computacionais para auxiliar os especialistas, são elas: Detecção Assistida por Computador - CADe (do inglês Computer-aided Detection) e Diagnóstico Assistido por Computador - CADx (do inglês Computer-aided Diagnosis).

O trabalho Nanni, Brahmam e Lumini (2012) utilizou a técnica *Multiresolution Local Phase Quantization*, baseada no trabalho Ojansivu e Heikkilä (2008), para a extração de característica utilizando 273 malignas e 311 benignas imagens da base *Digital Database for Screening Mammography* DDSM, obtendo *Area Under the Curve* (AUC) de 95.0, usando a *Máquina de Vetores de Suporte* (MVS) como classificador. A técnica *generalized dynamic fuzzy neural network* foi utilizada em Lim e Er (2004) utilizando 180 massas benignas e 163 massas malignas e obteve AUC de 0,868.

A utilização do Complete LBP(GUO; ZHANG; ZHANG, 2010) foi utilizada em Duarte, Nascimento e Oliveiras (2013) juntamente com *Wavelet Transform* e utilizando como classificador uma rede neural *Radial Basis Function* (RBF). A base de imagens utilizada foi a DDSM (240 benignas e 240 malignas) e obteve uma AUC com efetividade de 100%. Utilizando uma base própria contendo 91 malignas e 58 benignas, o trabalho Muramatsu et al. (2014) usando a técnica *Radial Local Ternary Pattern* e uma rede neural como classificador, obteve 0,848 de AUC.

Em [Oliver et al. \(2007\)](#) a técnica *Local Binary Pattern* (LBP) foi utilizada como extrator de características em 1024 *Regions Of Interest* (ROI's) da base DDSM e utilizou o classificador SVM, obtendo um AUC de 0,90. Um misto de características de textura e geometria foram utilizados para caracterizar as massas em [Nasseer e Mustafa \(2013\)](#), um conjunto de 100 imagens da base DDSM e o classificador SVM resultaram em 92,3% de Acurácia.

Este estudo utilizará somente a análise de textura dado que a dificuldade na análise de imagens de mamografias se dá, principalmente, quando as características geométricas não estão bem definidas, proporcionando ao especialista uma análise adicional. Abordagens de divisão espacial também são utilizadas a fim de estudar o comportamento que essas divisões geram quando são utilizadas em conjunto com as técnicas que aqui serão analisadas.

1.1 Objetivo

Este trabalho tem como objetivo fazer o diagnóstico do câncer de mama através da classificação de regiões extraídas de mamografias, que representem massas, em regiões benignas ou malignas. Para isto, utiliza-se técnicas de processamento digital de imagens, precisamente técnicas de análise de textura.

1.1.1 Objetivos Específicos

Especificamente buscamos:

- Estudar, analisar e implementar técnicas de LBP;
- Estudar, analisar e implementar abordagens de decomposição espacial de regiões;
- Compara-se 4 técnicas de análise de textura, cada uma utilizando somente seu histograma ou combinada com alguma das abordagens especificadas para analisarmos os resultados obtidos para o diagnóstico de câncer de mama.

1.2 Contribuições

A análise aqui realizada, entre as técnicas de padrões locais juntamente com as abordagens, contribui para futuras pesquisas na área de processamento digital de imagens, indicando quais técnicas desempenham-se melhor ao serem utilizadas em imagens de mamografia.

Especificamente pretende-se apresentar o desempenho da utilização das abordagens LBP's com decomposições espaciais das regiões e promover um avanço na aplicação de

abordagens baseadas em padrões locais binários para eficiente diagnóstico de câncer de mama usando mamografias.

1.3 Organização da Monografia

Esta monografia está dividida em cinco capítulos. No Capítulo 2 está apresentada a fundamentação teórica utilizada no desenvolvimento desta pesquisa.

No capítulo 3 estão descritos todos os procedimentos realizados para a classificação das regiões de massa, obtidas a partir de imagens de mamografia, entre malignas e benignas através do estudo proposto.

O capítulo 4 apresentamos resultados obtidos por meio dos experimentos realizados. O capítulo 5 apresenta as conclusões obtidas pela análise dos resultados bem como sugestões de trabalhos futuros.

2 Fundamentação Teórica

Este capítulo apresenta os conceitos básicos para o embasamento teórico da pesquisa aqui exposta. São abordados os conceitos de processamento digital de imagens, descritores de textura, exemplos de operadores que descrevem textura, sendo eles o *Local Binary Pattern* (LBP) e as variantes deste, sendo elas *Local Quinary Pattern* (LQP), *Center-Symmetric Local Binary Pattern* (CS-LBP) e *Compound Local Binary Pattern* (CLBP) e o classificador Máquina de Vetores de Suporte (MVS).

2.1 O processamento digital de imagens

Segundo [Gonzalez e Woods \(2006\)](#), o processamento digital de imagens são processos cujas entradas e saídas são imagens e, além disso, engloba processos que extraem atributos de imagens bem como o reconhecimento de objetos individuais. O processamento digital de imagens pode ser dividido em processos computadorizados. Processos de baixo, médio e alto nível, esses processos são diferenciados de acordo com o seu objetivo.

Processos de baixo nível envolvem operações primitivas como pré-processamento de imagem para reduzir ruídos, melhorar contrastes e tornar a imagem mais nítida. Um processo de baixo nível é caracterizado pelo fato que sua entrada e saída são imagens. Processos de médio nível em imagens envolvem tarefas como segmentação (particionar uma imagem em regiões ou objetos), descrições desses objetos para reduzi-los para uma forma conveniente para um processamento computadorizado, e classificação (reconhecimento) de objetos individuais. Um processo de nível médio é caracterizado pelo fato que suas entradas geralmente são imagens, mas suas saídas são atributos extraídos dessas entradas (por exemplo, arestas, contornos, ou uma característica que diferencia um objeto do outro). Finalmente, processamentos de alto nível envolvem extrair características dos objetos que os façam ser melhor compreendidos ou desempenhando as funções cognitivas normalmente associadas a visão.

2.2 Descritores de Textura

De acordo com [Bovik, Clark e Geisler \(1990\)](#), a textura pode ser utilizada na análise de imagens de várias maneiras: na segmentação de objetos distintos e regiões em cenários, na classificação ou reconhecimento na superfície de materiais ou no cálculo da forma da superfície.

Descritores de textura tem o objetivo de caracterizar a textura das imagens buscando

representar texturas semelhantes de formas semelhantes utilizando propriedades da textura, extraindo informações a partir de análises estatísticas, geométricas, estruturais, baseadas em modelo ou processamento de sinais (TUCERYAN; JAIN et al., 1993).

Um grande problema na análise da textura consiste na complexidade de texturas em aplicações práticas, onde normalmente estão sujeitas a mudanças de orientação, escala e/ou aparências visuais. Além disto, o grau de complexidade computacional de vários descritores de textura é bem alto (OJALA; PIETIKÄINEN; HARWOOD, 1996) conforme o estudo comparativo de Randen e Husoy (RANDEN; HUSOY, 1999).

2.3 Local Binary Pattern (LBP)

A técnica LBP (*Local Binary Pattern*) foi apresentada por Timo Ojala em Ojala, Pietikäinen e Harwood (1996), neste trabalho ele propõe uma abordagem teórica e computacionalmente simples, que é robusta em termos de variações nos níveis de cinza e que discrimina efetivamente uma larga gama de texturas rotacionadas. O LBP é um operador de textura invariante aos níveis de cinza e rotação, baseado em padrões locais binários.

Inicialmente devemos definir um arranjo de vizinhanças circularmente simétricas de P membros em um círculo de raio R . Dado este arranjo de vizinhanças, podemos definir a textura T em uma vizinhança local de uma imagem de textura monocromática como a distribuição conjunta dos níveis de cinza de P ($P > 1$) pixels da imagem.

$$T = t(g_c, g_0, \dots, g_{P-1}) \quad (2.1)$$

onde g_c é o nível de cinza do pixel central e $g_P(g_0, \dots, g_{P-1})$ corresponde aos valores de P igualmente espaçados em um círculo de raio R ($R > 0$). Se as coordenadas de g_c são $(0, 0)$ então as coordenadas de g_P são dadas por $(-R \sin \frac{2\pi p}{P}, R \cos \frac{2\pi p}{P})$ (Figura 1).

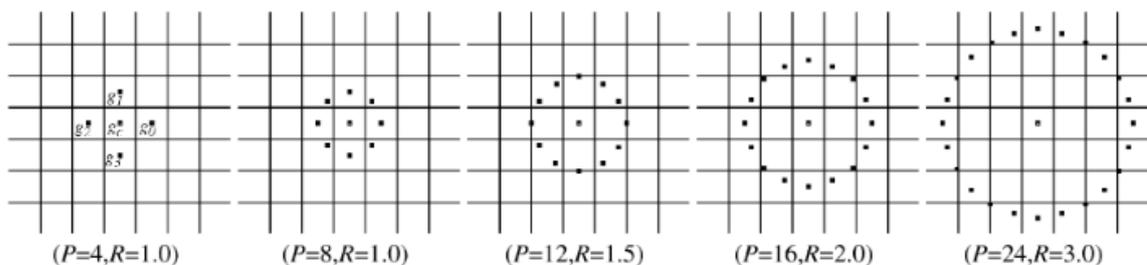


Figura 1: Vizinhanças circularmente simétricas para diferentes valores de P e R . Fonte: Retirado de (OJALA; PIETIKÄINEN; MÄENPÄÄ, 2002).

O LBP é então calculado como:

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (2.2)$$

onde $s(x)$ é uma função que devolve 1 se $x \geq 0$ ou 0, caso contrario.

Um exemplo do cálculo do LBP é apresentado na Figura 2.

6	5	2	1	0	0	1	2	4	1	0	0				
7	6	1	1		0	8		16	8		0				
9	3	7	1	0	1	32	64	128	32	0	128				
			a)				b)				c)				d)

Figura 2: Cálculo do LBP. (a) A imagem; (b) A imagem binária; (c) Matriz de Pesos; (d) Valores resultantes. Fonte: Retirado de (ROCHA, 2014).

Dada uma janela 3x3 (Figura 2a), os valores do pixel central é subtraído de cada um dos valores dos *pixels* vizinhos, o resultado da subtração é utilizado na função $s(x)$ que substituirá o valor anterior do *pixel* vizinho por 0 ou 1, dependendo do retorno da função $s(x)$ (Figura 2b). Cada valor da matriz binária é multiplicado pela sua respectiva posição na matriz de pesos (Figura 2c). O LBP é o resultado da soma de todos os valores resultantes das multiplicações (Figura 2d). O exemplo em questão tem como resultado do LBP o valor de 169.

2.4 Local Quinary Pattern (LQP)

Visando reduzir a sensibilidade ao ruído em regiões de imagens aproximadamente uniformes (LUMINI, 2010), o trabalho Nanni, Lumini e Brahmam (2012) sugeriu a utilização da codificação de cinco valores LQP (*Local Quinary Pattern*), a fim de obter um descritor mais robusto. No descritor sugerido, a diferença entre o valor de cinza do *pixel* central x dos níveis de cinza de cada um de seus vizinhos pode assumir 5 valores ao invés de 2 valores como no LBP padrão. A diferença s é codificada por cinco valores, de acordo com dois *thresholds* τ_1 e τ_2 :

$$s(x) = \begin{cases} 2 & \text{se } u \geq x + \tau_2; \\ 1 & \text{se } x + \tau_1 \leq u < x + \tau_2; \\ 0 & \text{se } x - \tau_1 \leq u < x + \tau_1; \\ -1 & \text{se } x - \tau_2 \leq u < x - \tau_1; \\ -2 & \text{caso contrário.} \end{cases} \quad (2.3)$$

O LQP é dividido em quatro padrões binários (Figura 3) de acordo com a seguinte função $b_c(x), c \in \{-2, -1, 1, 2\}$:

$$b_c(x) = \begin{cases} 1 & \text{se } x = c; \\ 0 & \text{caso contrário.} \end{cases} \quad (2.4)$$

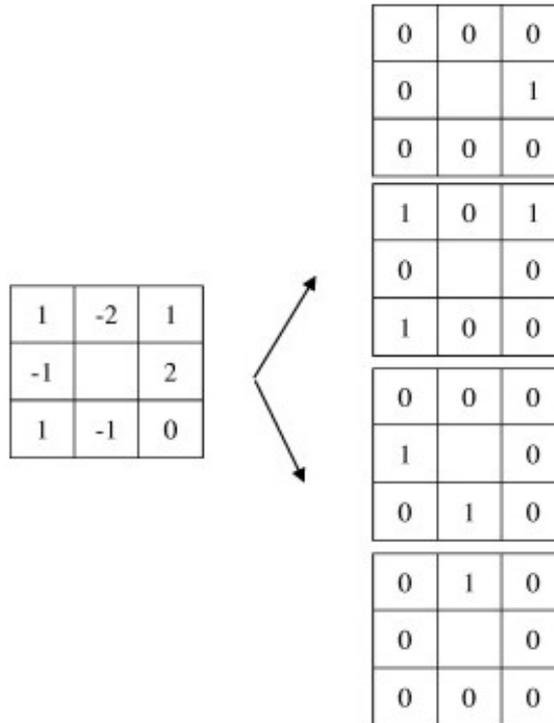


Figura 3: Um exemplo da divisão do código LQP em quatro códigos LBP. Fonte: Retirado de (NANNI; LUMINI; BRAHNAM, 2012).

A primeira codificação LBP é obtido considerando $c = 2$, a segundo considerando $c = 1$ e assim por diante, para $c = -1$ e $c = -2$. Após isso, cada codificação é calculada separadamente, gerando quatro matrizes LBP.

De posse das quatro matrizes, cada uma é calculada de acordo com o LBP tradicional, ou seja, multiplica-se os vetores binários pelas potências de 2. Os histogramas das imagens geradas são concatenados e utilizados como vetor de características.

2.5 Center-Symmetric Local Binary Pattern (CS-LBP)

Visando reduzir o tamanho dos histogramas gerados pelo operador do LBP, o *Center-Symmetric Local Binary Pattern* (CS-LBP) (HEIKKILÄ; PIETIKÄINEN; SCHMID, 2006) gera histogramas comparando pares de *pixels* simétricos em relação ao centro, produzindo histogramas mais compactos (veja a Figura 4). Em uma região de 8 vizinhos, o LBP tradicional produz 256 padrões diferentes, ao passo que o CS-LBP gera apenas 16 padrões.

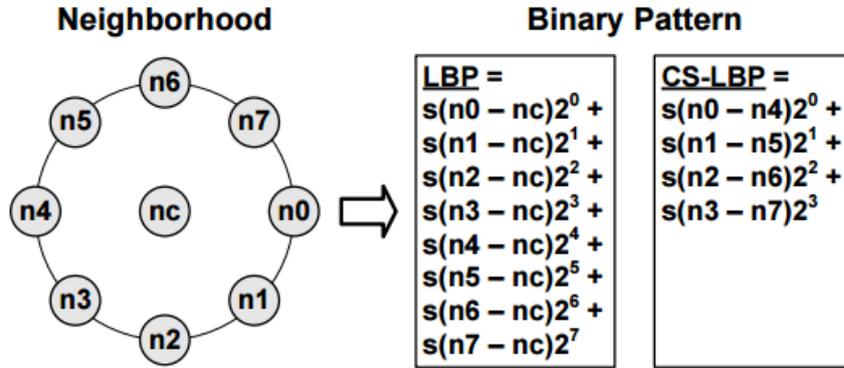


Figura 4: Exemplo da diferença entre o cálculo do LBP e do CS-LBP em uma vizinhança de 8 pixels, onde $s(x)$ é uma função que devolve 1 se $x \geq 0$ ou 0, caso contrário. Retirado de (HEIKKILÄ; PIETIKÄINEN; SCHMID, 2006).

O CS-LBP é definido formalmente na Equação 2.5. A robustez em imagens planas é obtida através da limiarização da diferença dos níveis de cinza utilizando um pequeno valor T .

$$CS-LBP_{R,N,T}(x, y) = \sum_{i=0}^{(N/2)-1} s(n_i - n_{i+(N/2)})2^i \quad (2.5)$$

onde R é o raio, N o número de vizinhos e T é o *threshold*. n_i e $n_{i+(N/2)}$ correspondem aos *pixels* simétricos em relação ao centro e $s(x)$ é uma função que devolve 1 se $x > T$ ou 0, caso contrário.

2.6 Compound Local Binary Pattern (CLBP)

Apesar do LBP ser teoricamente simples e ainda assim ser eficiente, esta técnica utiliza somente a informação gerada pelos sinais das diferenças entre o pixel central e os vizinhos e descarta a magnitude dessa diferença, que é uma importante informação sobre a textura.

O *Compound Local Binary Pattern* (CLBP) (AHMED et al., 2011) é uma extensão do operador LBP. Ao contrário do LBP, que usa P bits para codificar somente os sinais das diferenças entre o nível de cinza do pixel central e os níveis de cinza de P vizinhos, o CLBP emprega $2P$ bits, onde os P bits adicionais são utilizados para codificar a magnitude da diferença entre os níveis de cinza já citados.

A motivação do CLBP é aumentar a robustez da representação de características incorporando informação local adicional que é descartada pelo LBP tradicional. Além de

utilizar os P bits do LBP, o CLBP gera mais P bits de acordo com a Equação 2.6.

$$s(i_p, i_c) = \begin{cases} 1 & \text{se } |i_p - i_c| > M_{avg} \\ 0 & \text{caso contrário.} \end{cases} \quad (2.6)$$

onde M_{avg} é média da magnitude da diferença entre i_p e i_c na vizinhança local.

Em uma vizinhança 3×3 , o CLBP opera com 8 vizinhos ao redor do *pixel* central, gerando um código de 16 bits. Para reduzir o número de características, esse código é dividido em dois códigos sub-CLBP. Cada sub-CLBP é obtido concatenando os valores da sequência de bits (1, 2, 5, 6, ..., $2P - 3$, $2P - 2$) e (3, 4, 7, 8, ..., $2P - 1$, $2P$), respectivamente do código $2P$ bits original do CLBP, representado na Figura 5.

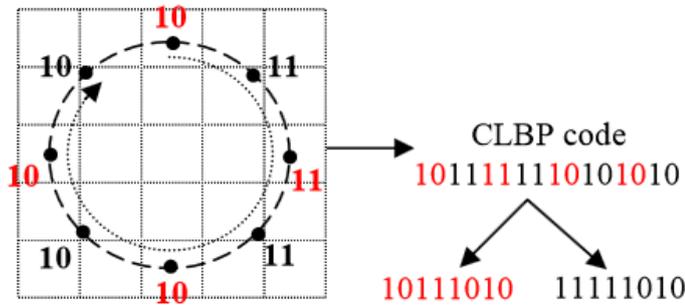


Figura 5: Geração dos códigos sub-CLBP a partir do código original do CLBP. Retirado de (AHMED et al., 2011).

Os dois códigos sub-CLBP são tratados como códigos binários separados, sendo estes calculados separadamente. A partir das imagens geradas, extraímos os histogramas e concatena-se ambos gerando o vetor de características.

2.7 Máquina de Vetores de Suporte

A máquina de vetores de suporte (MVS) é um método de aprendizagem supervisionado usado para estimar uma função que classifique dados de entrada em duas classes, sendo que o princípio básico por trás da MVS é a construção de um hiperplano que sirva como superfície de decisão, em que a margem de separação entre as classes seja máxima. Assim, a finalidade do treinamento através da MVS é a obtenção de hiperplanos que dividam as amostras de tal modo que sejam otimizados os limites de generalização (VAPNIK, 2013).

Um hiperplano pode ser compreendido como uma superfície de separação de duas regiões em um espaço multidimensional, em que o número de dimensões possíveis pode ser muito grande ou até mesmo infinito. Mesmo quando as duas classes não são separáveis, a MVS é capaz de encontrar um hiperplano através do uso de conceitos pertencentes a teoria da otimização. Porém, quando o conjunto de amostras é composto por duas classes

separáveis, um classificador MVS é capaz de encontrar um hiperplano baseado em um conjunto de pontos, chamados vetores de suporte, o qual maximiza a margem de separação entre as classes (VAPNIK, 2013).

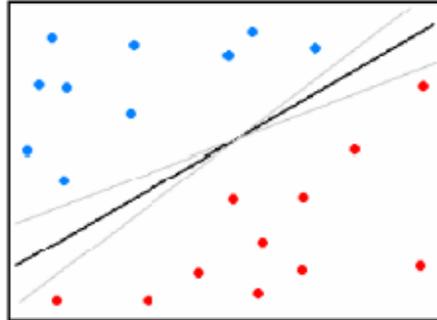


Figura 6: Separação de duas classes através de duas classes de hiperplanos. Fonte: Retirado de (ROCHA, 2014).

A Figura 6 exemplifica hiperplanos de separação entre duas classes linearmente separáveis. A linha central representa o hiperplano ótimo, pois separa as duas classes e mantém a maior distância possível com relação aos pontos da amostra.

Dado o conjunto de treinamento (x_i, y_i) , sendo $x_i \in \mathfrak{R}^n$ o vetor de entrada, y_i a classificação correta das amostras e $i = 1, \dots, n$ o índice de cada ponto amostral. O objetivo da classificação é estimar a função $f: \mathfrak{R}^n \rightarrow \{\pm 1\}$, que separe corretamente os exemplos de teste em classes distintas (VAPNIK, 2013).

A etapa de treinamento estima a função $f(x) = (w \cdot x) + b$, procurando por valores de w e b tais que a relação, representada pela Equação 2.7 seja satisfeita.

$$y_i((w \cdot x_i) + b) \geq 1 \quad (2.7)$$

onde w é o vetor normal ao hiperplano de decisão e b o corte ou distancia da função f em relação a origem. Os valores ótimos de w e b serão encontrados ao minimizar a Equação 2.8, de acordo com a restrição dada pela Equação 2.7 (CHAVES, 2006).

$$\Phi(w) = \frac{w^2}{2} \quad (2.8)$$

A MVS ainda permite encontrar um hiperplano que minimize a ocorrência de erros de classificação incluindo variáveis de folga, as quais permitem que as restrições presentes na equação 2.7 sejam quebradas.

Dessa forma o problema passa a ser de minimização da Equação 2.9, conforme a restrição imposta pela Equação 2.7, no qual C é um parâmetro de treinamento que irá

determinar um equilíbrio entre a complexidade do modelo e o erro de treinamento, sendo este escolhido pelo usuário (VAPNIK, 2013).

$$\Phi(w, \xi) = \frac{w^2}{2} + C \sum_{i=1}^N \xi_i \quad (2.9)$$

$$y_i((w \cdot x_i) + b) + \xi_i \geq 1 \quad (2.10)$$

A Equação 2.11 é alcançada através da teoria dos multiplicadores de Lagrange, cujo objetivo é encontrar os multiplicadores de Lagrange α_i ótimos que satisfaçam a Equação 2.12.

$$w(\alpha) = \sum_{i=1}^N \alpha_i - 1/2 \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j (x_i, x_j) \quad (2.11)$$

$$\sum_{i=1}^N \alpha_i y_i = 0, 0 \leq \alpha_i \leq C \quad (2.12)$$

Somente para os pontos onde a restrição da Equação 2.7 seja exatamente igual unidade terá correspondente $\alpha \neq 0$. Estes pontos são chamados de vetores de suporte, pois se localizam geometricamente sobre as margens.

Os pontos que representam os vetores de suporte estão destacados na Figura 7. Os pontos além da margem não influenciam decisivamente na determinação do hiperplano, enquanto os vetores de suporte, por terem pesos não nulos, são decisivos (VAPNIK, 2013).

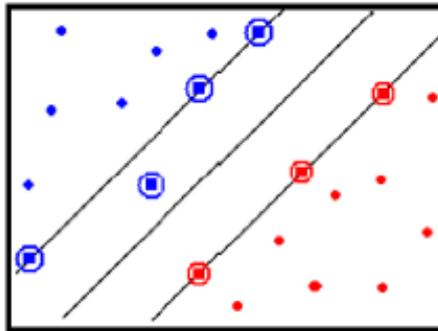


Figura 7: Vetores de Suporte para determinação do hiperplano de separação (destacados por círculos). Fonte: Retirado de (ROCHA, 2014).

Há ainda os casos em que as amostras não são linearmente separáveis, a MVS necessita de uma transformação não-linear que transforme o espaço de entrada (dados) para um novo espaço (espaço de característica). Este espaço deve ter dimensão suficientemente

grande e por meio deste a amostra possa ser linearmente separável. Esta transformação depende do cálculo de uma função K de núcleo de um produto interno.

A Equação 2.13 apresenta o resultado da Equação 2.11 com a utilização de um núcleo K .

$$w(\alpha) = \sum_{i=1}^N \alpha_i - 1/2 \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (2.13)$$

Há uma grande variedade de funções de núcleo, podendo encontrada-las em uma variedade de aplicações. Nesta monografia a *Radial Basis Function* (RBF) $\exp(-\gamma \|x_i - x_j\|^2)$ será usada.

3 Metodologia

Este capítulo descreve os procedimentos utilizados neste trabalho para estudo do diagnóstico do câncer de mama usando Local Binary Patterns. A Figura 8 apresenta as etapas do estudo, que são: Aquisição de Imagens, Decomposição da ROI, Extração de Características e Reconhecimento de Padrões.

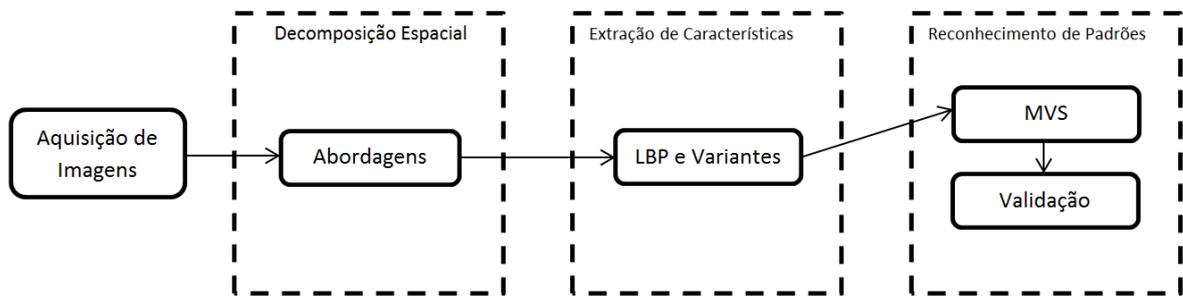


Figura 8: Representação da metodologia deste estudo

3.1 Aquisição de Imagens

A primeira etapa do estudo é dedicada a obtenção da base de imagens adotada por este trabalho. A base escolhida foi a *Digital Database for Screening Mammography* (DDSM) (HEATH et al., 2000). A DDSM é uma base pública e está disponível na internet, sendo esta composta por imagens de mamografias digitalizadas a partir de imagens de radiografias.

A DDSM é formada por um total de 2620 casos de pacientes de diferentes origens étnicas e raciais, tem até duas imagens de cada mama nas projeções crânio-caudal e médio-lateral oblíqua. Arquivos com descrições das lesões são fornecidos juntamente com imagens que apresentam áreas suspeitas com massas. Estes contem informações como quantidade de lesões, localização destas lesões, os tipos das lesões entre outras informações.

Os testes utilizaram amostras obtidas segundo a abordagem utilizada em Junior (2008). Esta abordagem visa extrair *bounding boxes* (os menores retângulos que envolvem a ROI) das imagens, contendo somente as regiões com massas, totalizando 3559 ROIs.

Neste trabalho utilizamos um subconjunto de 1155 ROIs, sendo 625 massas malignas e 530 massas benignas. A Figura 9 apresenta exemplos de ROIs utilizadas neste trabalho.

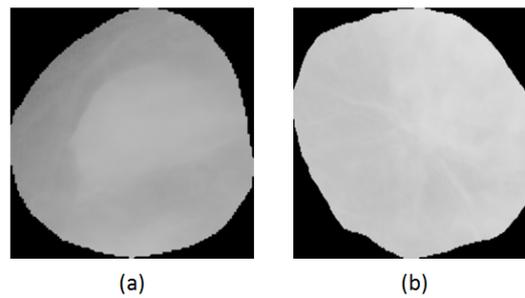


Figura 9: A Figura (a) representa uma lesão benigna a Figura (b) representa uma lesão maligna

3.2 Decomposição Espacial

O objetivo desta etapa é gerar uma representação mais adequada para o propósito da análise de textura. Nela, a ROI é o resultado da aplicação de uma abordagem que será usada como entrada para técnicas de análise de textura.

Neste estudo, utilizamos pares de abordagem/técnica para cada uma das ROIs a fim de encontrar a distribuição espacial de padrões locais de textura existentes na mesma.

As abordagens, no contexto deste trabalho, são transformações realizadas na ROI original que tem como objetivo dividi-la em sub-regiões que permitam a análise separada.

A primeira abordagem utilizada foi a *Cartesian Grid* que visa dividir a ROI como uma grade. A função é parametrizada por m e n , onde m é o número de divisões horizontais e n é o número de divisões verticais. A quantidade de ROIs resultantes é dado por $m \times n$. Neste trabalho, utilizamos a *Cartesian Grid* 2x2 e 4x4.

A Figura 10a representa a abordagem *Cartesian Grid* 2x2, a Figura 10b representa a ROI original com a *grid* 4x4. A Figura 10c e d são exemplos de quadrantes obtidos do *Cartesian Grid*.

A segunda abordagem utilizada foi a *Grid X*, que não tem parâmetros. Essa abordagem simplesmente divide a ROI utilizando as suas duas diagonais principais e gera 4 triângulos.

A Figura 11 exemplifica a abordagem *Grid X*, onde a Figura 11a é a ROI original com as diagonais do *Grid X* traçadas sobre ela. As Figuras 11b e c são duas das quatro imagens resultantes desta abordagem.

A terceira abordagem utilizada foi a *Complete Grid* que utiliza tanto a *Cartesian Grid*(2x2) quanto a *Grid X*, essa abordagem gera 8 triângulos e não é parametrizada.

A Figura 12 representa a abordagem *Complete Grid*, onde a Figura 12a é a ROI original com a *grid* 2x2 e suas diagonais principais, a Figura 12b representa exemplos dos triângulos obtidos por esta abordagem.

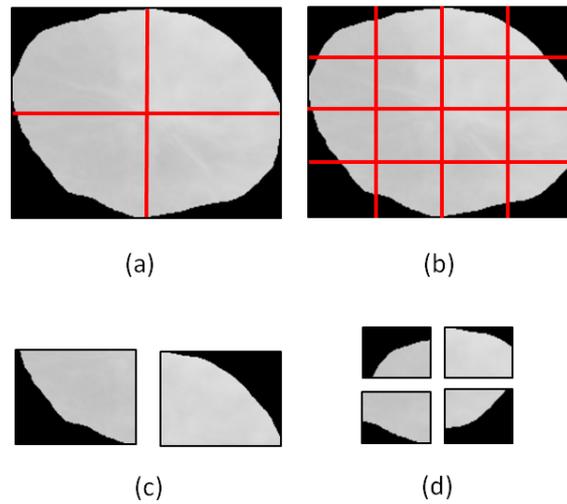


Figura 10: Exemplos de *Cartesian Grid*. Em (a) 2x2, em (b) 4x4 e em (c) e (d) exemplos das ROIs resultantes.

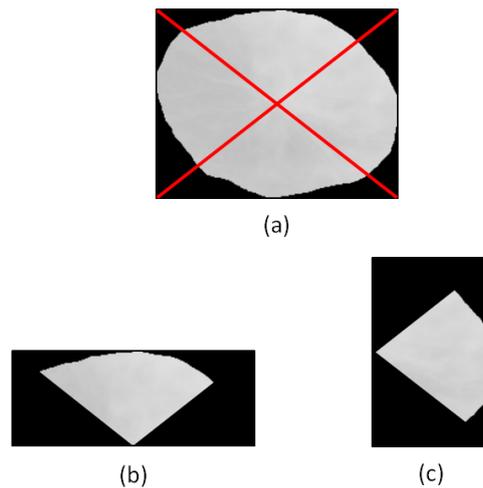


Figura 11: Exemplo de *Grid X*.

A abordagem circular foi a quarta abordagem utilizada neste trabalho, esta abordagem é parametrizada pelo valor de n , onde n é a quantidade de círculos concêntricos a serem gerados, sendo o centro desses círculos o centro da ROI. Uma variação desta abordagem também foi utilizada, rotulada de abordagem de anéis circulares, onde anéis são gerados no lugar dos círculos preenchidos. Neste trabalho, utilizamos a abordagem circular e a abordagem anéis circulares com $n = 2$.

A abordagem circular está representada na Figura 13, a Figura 13a representa a ROI original com $n = 2$. A Figura 13b demonstra os dois círculos gerados por esta abordagem.

A variação da abordagem circular, anéis circulares, está demonstrada na Figura 14,

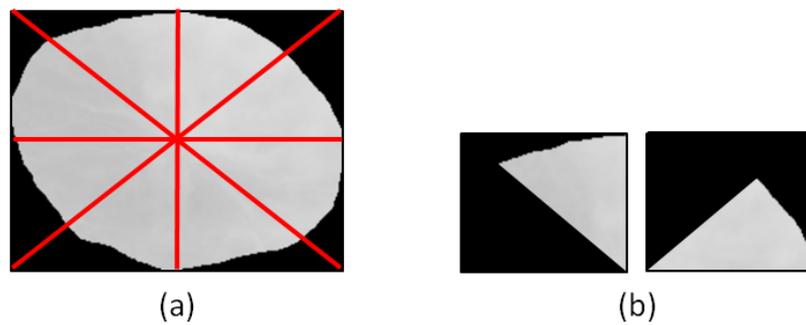


Figura 12: Exemplo de *Complete Grid*.



Figura 13: Exemplo da abordagem circular.

onde a Figura 14a representa a ROI original com os dois anéis circulares concêntricos ($n = 2$). A Figura 14b demonstra os dois anéis circulares gerados por esta abordagem.

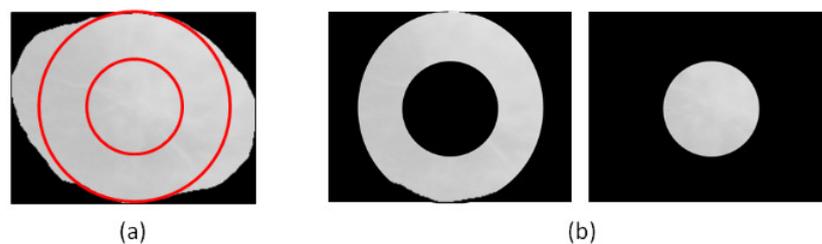


Figura 14: Exemplo da abordagem dos anéis circulares.

A quinta abordagem utilizada foi a elíptica, esta abordagem tem o mesmo parâmetro da abordagem circular, a diferença é que ela gera elipses concêntricas. Uma variação desta abordagem também foi utilizada neste trabalho, rotulada de anéis elípticos, onde anéis são gerados no lugar das elipses preenchidas.

A elipse é obtida dividindo a largura e a altura pelo número n de elipses concêntricas e com base no resultado obtido através dessa divisão a elipse é gerada.

A abordagem elíptica está representada na Figura 15, a Figura 15a representa a ROI original com $n = 2$. A Figura 15b demonstra as duas elipses geradas por esta abordagem.

A variação da abordagem elíptica, anéis elípticos, está representada na Figura 16,

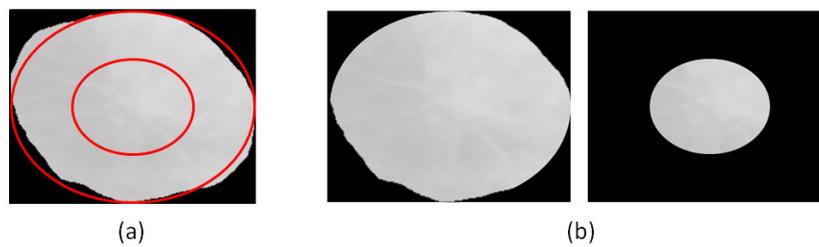


Figura 15: Exemplo da abordagem elíptica.

onde a Figura 16a representa a ROI original as duas elipses concêntricas ($n = 2$). A Figura 16b demonstra os dois anéis elípticos gerados por esta abordagem.

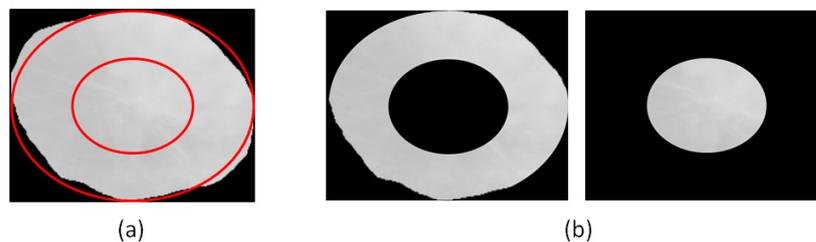


Figura 16: Exemplo da abordagem dos anéis elípticos

3.3 Extração de Características

As técnicas utilizadas neste trabalho, a saber: *Local Binary Pattern* (LBP), *Local Quinary Pattern* (LQP), *Center-Symmetric Local Binary Patterns* (CS-LBP) e *Compound Local Binary Pattern* (CLBP), foram aplicadas para todas as abordagens descritas na Seção 3.2.

A primeira técnica, LBP, foi aplicada em sua forma padrão, cujo cálculo é feito em uma janela 3×3 , ou seja, $\text{raio}(R) = 1$ e número de vizinhos(N) = 8.

A segunda técnica, LQP, também foi aplicada em janela 3×3 . Os *thresholds* τ_1 e τ_2 utilizados no cálculo do LQP foram iguais a 1 e 10 respectivamente.

A terceira técnica, CS-LBP, também foi calculado em uma janela 3×3 e *threshold* T igual a 0.

A quarta e última técnica, CLBP, foi calculada em janela 3×3 e o *threshold* τ_1 utilizado no cálculo do CLBP foi utilizado como a média dos módulos das diferenças entre o centro e os valores de nível de cinza vizinhos.

Para cada abordagem, os histogramas parciais (aplicado em cada recorte resultante da abordagem específica aplicada) foram normalizados e concatenados, formando a base

de característica. A Tabela 1 apresenta a quantidade de características geradas para cada combinação abordagem/técnica com extração de características.

Tabela 1: Quantidade de características geradas para cada par abordagem/técnica

	2x2	4x4	Grid X	Comp. Grid	Circular	Elíptica
LBP	1024	4096	1024	2048	512	512
LQP	4096	16.384	4096	8192	2048	2048
CS-LBP	1024	4096	1024	2048	512	512
CLBP	2048	8192	2048	4096	1024	1024

3.4 Reconhecimento de Padrões

Com o objetivo de fazer a validação dos resultados obtidos medindo o desempenho de cada um dos pares abordagem/técnica com o auxílio de algumas estatísticas, esta subseção foi incluída neste estudo e é detalhada em seguida.

Conforme descrito na Sessão 2.7, o objetivo desta etapa consiste em classificar cada massa em massa maligna ou massa benigna utilizando o reconhecimento de padrões.

Os experimentos foram realizados de acordo com o fluxo de atividades descrito pela Figura 17. A base de características foi normalizada entre -1 e 1. Esse processo tem como objetivo padronizar a distribuição de valores das variáveis, que podem assumir diferentes domínios. Além disso, busca ajudar o classificador a convergir com maior facilidade na etapa de treinamento. Portanto, utilizou-se o *svm-scale* presente no pacote *libSVM*¹ (CHANG; LIN, 2011) para realizar esta tarefa.

Após a etapa de normalização, a base de característica foi dividida em base de treino e base de teste. Este trabalho adotou vários critérios para a divisão entre base de treino e teste, a saber: 50/50, 60/40, 70/30 e 80/20.

A divisão treino e teste foi realizada 5 vezes aleatoriamente para eximir o processo de reconhecimento de efeitos de correlação. Cada base de treinamento teve parâmetros estimados. Foram estimados os parâmetro de custo C e o grau de complexidade da função de mapeamento γ utilizados pela MVS. Para tanto, usou-se o *script* em *python* conhecido como: *grid.py* presente no pacote *libSVM*. Este *script* busca através da validação cruzada, a melhor combinação de parâmetros para a base que retorne como resposta o melhor percentual de acerto total sobre as amostras de treino e teste (ROCHA, 2014).

Ao final da etapa de treinamento é produzido o modelo (função) com os vetores de suporte que a MVS utilizará para classificar as amostras de teste. Desta forma, esta construção de classificação busca se aproximar as condições reais de teste. Então o modelo

¹ Este pacote contém a implementação da MVS utilizada neste trabalho

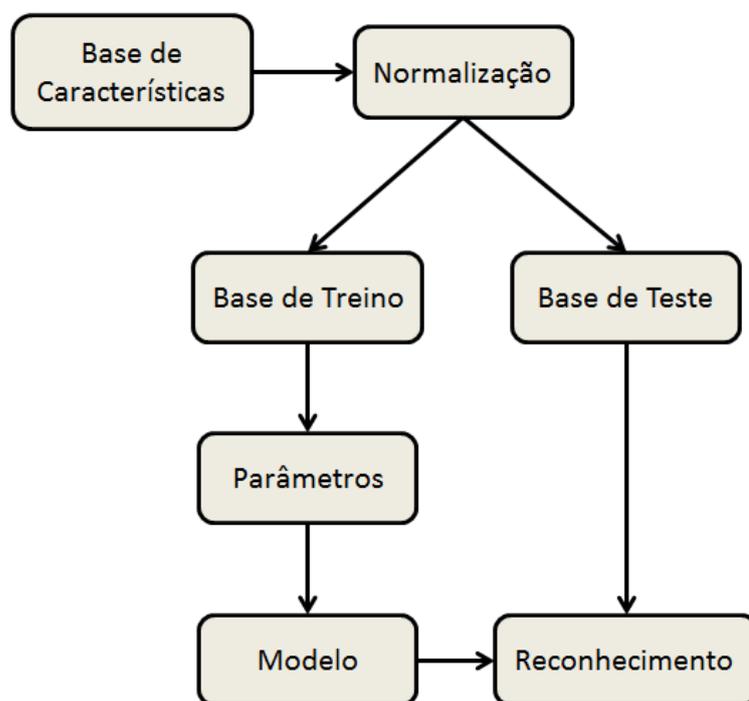


Figura 17: Fluxo da metodologia para reconhecimento de padrões.

gerado por ser utilizado para realizar a etapa de reconhecimento de padrões com amostras de teste separadas.

3.5 Validação dos Resultados

O objetivo dessa etapa consiste em medir o desempenho e promover a validação dos resultados obtidos. Este trabalho utiliza as estatísticas: Acurácia, Sensibilidade e Especificidade, Precisão e *F-Score*.

Estas estatísticas são calculadas com base na matriz de confusão (Tabela 2). A matriz de confusão correlaciona os valores obtidos pela classificação da MVS com os valores da marcação do especialista.

A Tabela 2 representa um exemplo de matriz de confusão, relacionando os valores das classes verticais(marcações do especialista) e o valores das classes horizontais (classificado pela MVS). A MVS classificou como *a* dez indivíduos Malignos corretamente e um como Benigno, então temos 10 VP (Verdadeiros Positivo) e 1 FP (Falsos Positivo), a mesma coisa nós temos para a classe Benigna, com 15 VN (Verdadeiros Negativo) e 2 FN (Falsos Negativo).

Visando uma maior robustez, as matrizes de confusão obtidas neste estudo são a média de 5 testes realizados com os mesmos parâmetros, abordagens e técnicas, somente

Tabela 2: Exemplo de matriz de confusão

	Maligno	Benigno
Maligno	10	1
Benigno	2	15

variando os indivíduos utilizados para treino e teste.

A acurácia é definida na Equação 3.1, corresponde à taxa de classificação correta, sendo definida como a razão entre o número de casos na amostra em estudo que foram classificados corretamente e o número total de amostras.

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad (3.1)$$

A sensibilidade (Equação 3.2 define a proporção de Verdadeiros Positivos identificados nos testes, indicando o quão bom o teste é para identificar os padrões malignos (Padrão mais significante à ser identificado).

$$Sensibilidade = \frac{VP}{VP + FN} \quad (3.2)$$

A especificidade, definida na Equação 3.3, mede a proporção de Verdadeiros Negativos identificados no teste, indicando o quão bom o teste é para identificar os padrões benignos.

$$Especificidade = \frac{VN}{VN + FP} \quad (3.3)$$

A precisão (Equação 3.4) representa a proporção de Verdadeiros Positivos quando consideramos a quantidade de Positivos classificados no teste, indicando o quão bom esse teste é para identificar padrões malignos com o menor número de classificações malignas.

$$Precisão = \frac{VP}{VP + FP} \quad (3.4)$$

A *F-Score* é uma média harmônica entre a precisão e a sensibilidade. Esta é definida na Equação 3.5, pode ser interpretada como uma média ponderada entre precisão e sensibilidade, onde o resultado está no intervalo entre 0 e 1, quanto mais próximo de 1 melhor é o teste.

$$F-Score = 2 \left(\frac{Precisão \times Sensibilidade}{Precisão + Sensibilidade} \right) \quad (3.5)$$

4 Resultados

Este capítulo apresenta os resultados produzidos pelo estudo apresentado e a análise dos mesmos. Os resultados estão organizados de acordo com a ordem de abordagem utilizada.

Conforme descrito na Seção 3.4, em cada proporção treino/teste, cinco repetições foram realizadas. Os parâmetros utilizados foram estimados usando validação cruzada, técnica implementada na biblioteca de referência utilizada.

4.1 Histograma

Um teste utilizando somente a frequência do histograma gerado por cada uma das técnicas utilizadas na ROI sem nenhuma das abordagens foi realizado, a média dos resultados da F-Score esta apresentado na Figura 18.

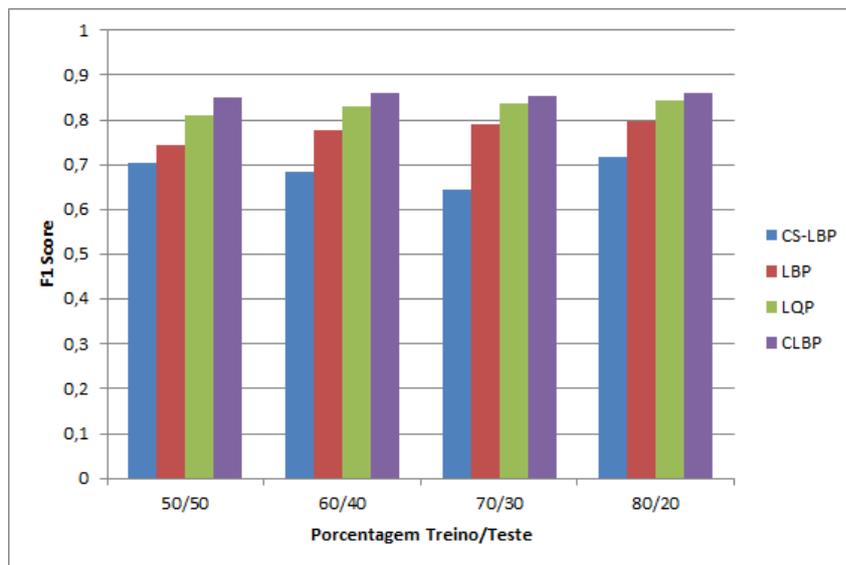


Figura 18: Gráfico das médias da F-Score utilizando os histogramas para cada uma das técnicas de acordo com a porcentagem de treino utilizada.

O melhor resultado obtido no teste utilizando somente a informação do histograma foi obtido na aplicação da CLBP com a proporção de treino/teste 80/20, este obteve o valor F-Score de 0.8612.

4.2 Abordagem *Cartesian Grid*

Esta abordagem foi aplicada utilizando *grid* 2x2 e 4x4. Para a *grid* 2x2, a média dos resultados da F-Score esta apresentada na Figura 19.

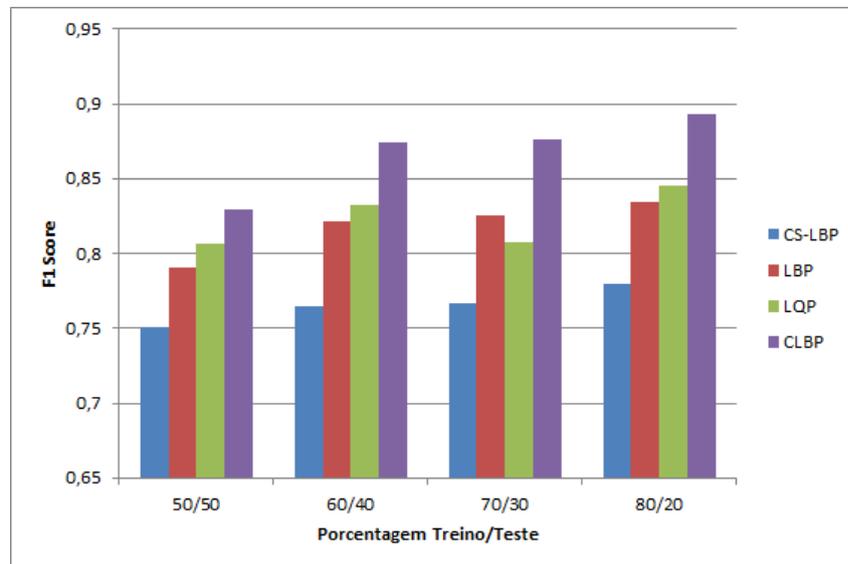


Figura 19: Gráfico da F-Score da *grid* 2x2 para cada uma das técnicas de acordo com a porcentagem de treino utilizada.

Na aplicação da abordagem *grid* 2x2 é possível observar que o melhor resultado foi obtido na aplicação da CLBP com a proporção treino/teste 80/20, este obteve o valor F-Score de 0,8928.

As médias da estatística F-Score da *grid* 4x4 encontram-se na Figura 20.

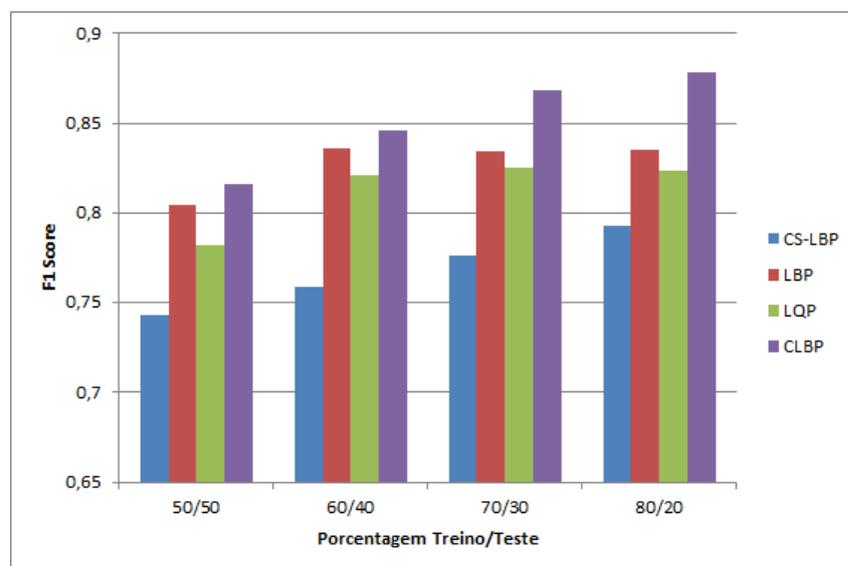


Figura 20: Gráfico da F-Score da *grid* 4x4 para cada uma das técnicas de acordo com a porcentagem de treino utilizada.

Na aplicação da abordagem *grid* 4x4 é possível observar que o melhor resultado foi obtido na aplicação da CLBP com a proporção treino/teste 80/20, este obteve o valor F-Score de 0.8783.

4.3 Abordagem *Grid X*

Foi realizado um experimento da abordagem *Grid X* com cada uma das técnicas. A média dos resultados obtidos para a F-Score estão apresentados na Figura 21.

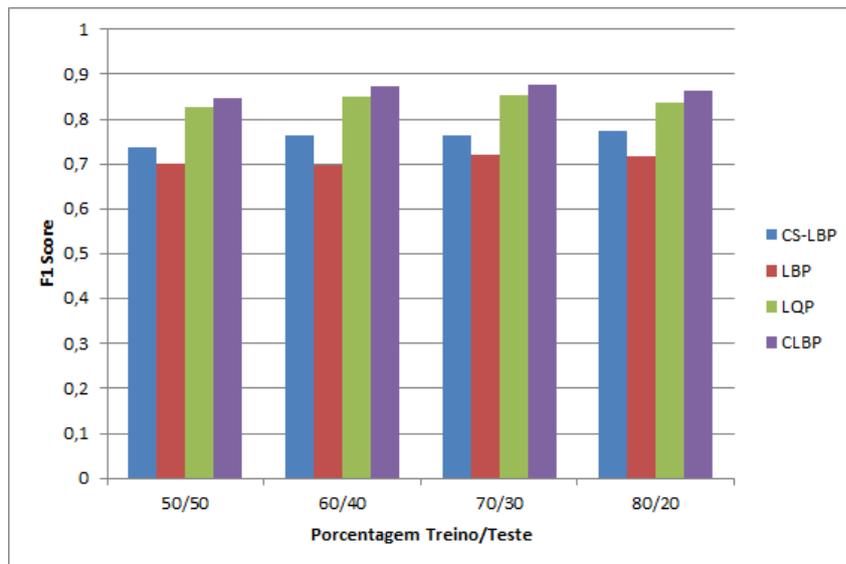


Figura 21: Gráfico da F-Score da *Grid X* para cada uma das técnicas de acordo com a porcentagem de treino utilizada.

O melhor resultado obtido na aplicação da abordagem *Grid X* foi obtido na aplicação da CLBP com a proporção de treino/teste 70/30, este obteve o valor F-Score de 0.8750.

4.4 Abordagem *Complete Grid*

No experimento da abordagem *Complete Grid* com cada uma das técnicas. A média dos resultados obtidos para a F-Score estão apresentados na Figura 22.

O melhor resultado obtido na aplicação da abordagem *Complete Grid* foi obtido na aplicação da CLBP com a proporção de treino/teste 80/20, este obteve o valor F-Score de 0.8883.

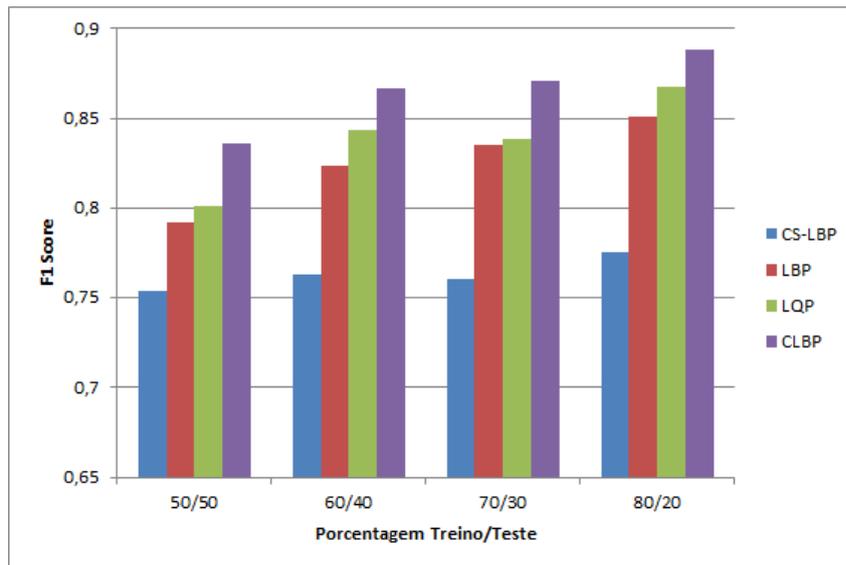


Figura 22: Gráfico da F-Score da *Complete Grid* para cada uma das técnicas de acordo com a porcentagem de treino utilizada.

4.5 Abordagem Circular

Para o experimento da abordagem Circular com cada uma das técnicas. A média dos resultados obtidos para a F-Score estão apresentados na Figura 23.

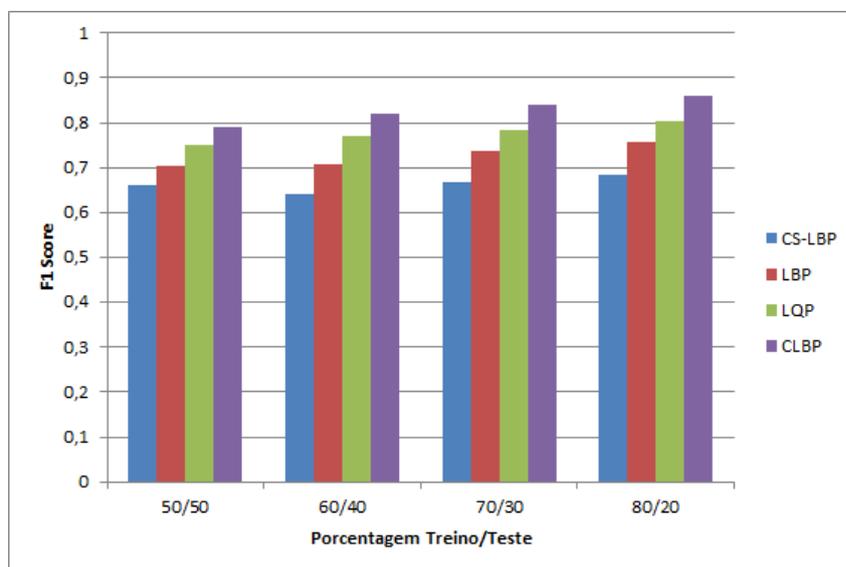


Figura 23: Gráfico da F-Score da abordagem Circulares para cada uma das técnicas de acordo com a porcentagem de treino utilizada.

O melhor resultado obtido na aplicação da abordagem Circular foi obtido na aplicação da CLBP com a proporção de treino/teste 80/20, este obteve o valor F-Score de 0.8585.

Um experimento utilizando a variante da abordagem Circular, Anéis Circulares,

foi realizado com cada uma das técnicas. A média dos resultados obtidos para a F-Score estão apresentados na Figura 24.

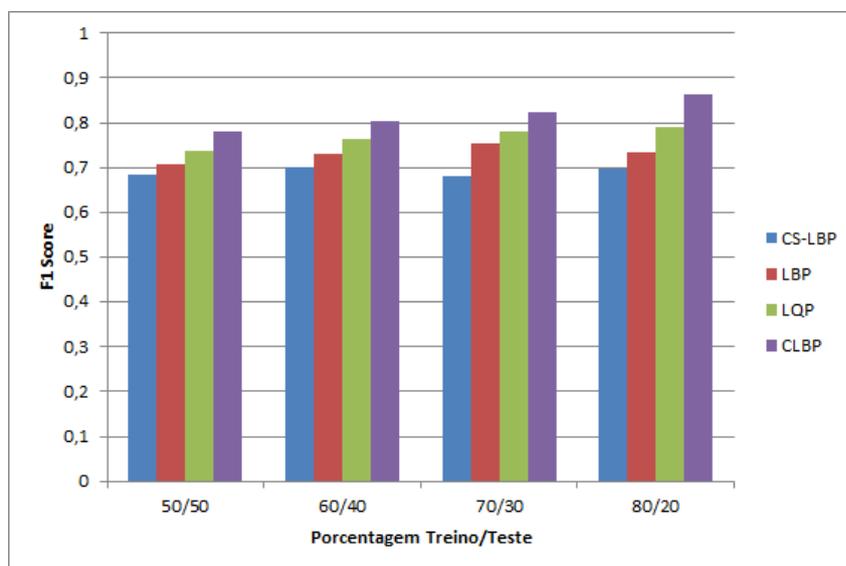


Figura 24: Gráfico da F-Score da abordagem Anéis Circulares para cada uma das técnicas de acordo com a porcentagem de treino utilizada.

O melhor resultado obtido na aplicação da abordagem Anéis Circulares foi obtido na aplicação da CLBP com a proporção de treino/teste 80/20, este obteve o valor F-Score de 0.8624.

4.6 Abordagem Elíptica

Foi realizado um experimento da abordagem Elíptica com cada uma das técnicas. A média dos resultados obtidos para a F-Score estão apresentados na Figura 25.

O melhor resultado obtido na aplicação da abordagem Elíptica foi obtido na aplicação da CLBP com a proporção de treino/teste 70/30, este obteve o valor F-Score de 0.8648.

Um experimento utilizando a variante da abordagem Elíptica, Anéis Elípticos, foi realizado com cada uma das técnicas. A média dos resultados obtidos para a F-Score estão apresentados na Figura 26.

O melhor resultado obtido na aplicação da abordagem Elíptica foi obtido na aplicação da CLBP com a proporção de treino/teste 80/20, este obteve o valor F-Score de 0.8790.

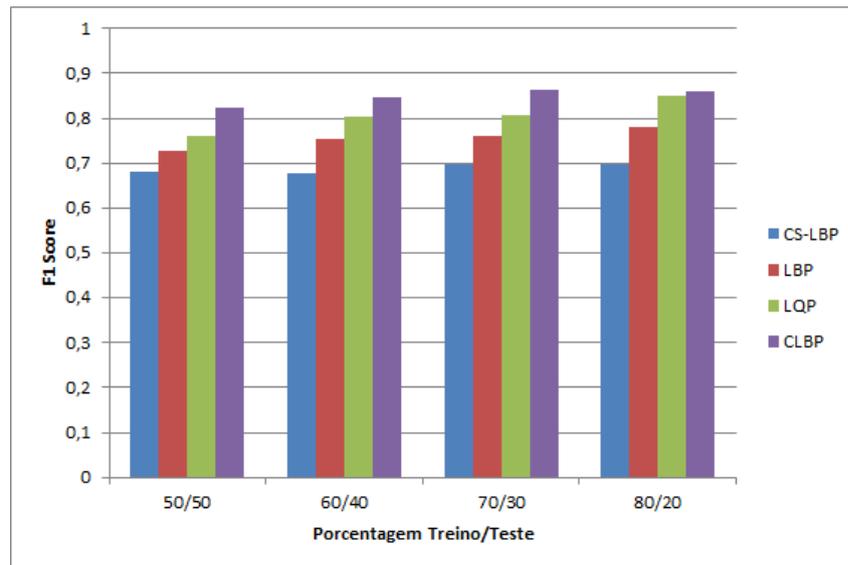


Figura 25: Gráfico da F-Score da abordagem Elíptica para cada uma das técnicas de acordo com a percentagem de treino utilizada.

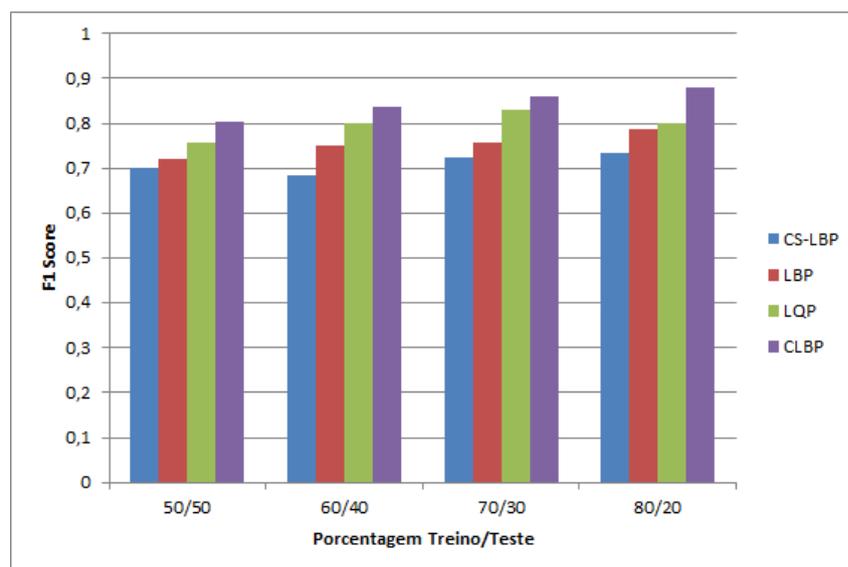


Figura 26: Gráfico da F-Score da abordagem Anéis Elípticos para cada uma das técnicas de acordo com a percentagem de treino utilizada.

4.7 Quadro Geral dos Resultados

Observando os resultados obtidos, a aplicação com o melhor desempenho foi a CLBP, que obteve os melhores resultados dentre todas as técnicas em todas as abordagens. A possível explicação para o seu desempenho é que o CLBP utiliza mais informações do que as outras técnicas, utilizando não só as informações dos sinais, mas também utilizando as informações das magnitudes das diferenças entre os *pixels* da vizinhança e o *pixel* central.

Tabela 3: Quadro da melhor técnica (CLBP) juntamente com as 3 melhores abordagens, mostrando todas as informações estatísticas relevantes.

	Proporção	Acurácia	Sensibilidade	Especificidade	F-Score
<i>Cartesian Grid 2x2</i>	50/50	82,18	79,87	84,91	0,8291
	60/40	87,01	83,12	91,60	0,8738
	70/30	87,38	82,23	93,46	0,8759
	80/20	89,09	84,00	95,09	0,8929
<i>Complete Grid</i>	50/50	83,08	79,68	87,09	0,8361
	60/40	86,41	81,36	92,36	0,8664
	70/30	86,97	81,17	93,84	0,8710
	80/20	88,74	82,72	95,85	0,8882
Anéis Elípticos	50/50	79,52	76,75	82,79	0,8022
	60/40	83,59	78,00	90,19	0,8373
	70/30	86,28	78,62	95,35	0,8613
	80/20	87,71	82,56	93,77	0,8791

5 Conclusão

Para os especialistas é difícil fazer o diagnóstico através de imagens de mamografia utilizando somente características de geometria quando estas não estão bem definidas, sendo muito comum que os mesmos encaminhem seus pacientes para exames mais invasivos, como biópsias. Este fato se dá a difícil tarefa da análise de textura, pois é muito comum que essas massas possuam características de textura semelhantes.

O objetivo deste estudo foi, dado a dificuldade da análise de textura, realizar um estudo comparativo utilizando exclusivamente técnicas de análise de textura, de modo a fornecer uma segunda opinião ao especialista quando este se depara com imagens que não apresentem características geométricas bem definidas.

Para este objetivo, foram comparadas 4 técnicas de análise de textura, visando o direcionamento do seu uso aos problemas de diagnóstico de padrões de malignidade e benignidade em imagens de mamografia.

Das técnicas utilizadas, o CLBP foi o que apresentou os melhores resultados em todos os testes, sendo o melhor deles obtendo o F-Score de 0,8928 na proporção 80/20.

5.1 Trabalhos Futuros

Dado o grande interesse por parte da comunidade científica, espera-se que este trabalho contribua para o desenvolvimento de novas pesquisas com o mesmo objetivo. Assim, como sugestão de trabalhos futuros estão:

1. Aplicar pré-processamento as imagens, como por exemplo testar o realce logarítmico e analisar os resultados;
2. Comparar um maior número de técnicas, buscando a que melhor desempenha o papel para um bom descritor de textura;
3. Utilizar outros parâmetros na aplicação das abordagens, analisando seus efeitos;
4. Usar técnicas como por exemplo: Matrizes de Níveis de Cinza como a *Gray Level Cooccurrence Matrix* (HARALICK; SHANMUGAM; DINSTEN, 1973) ou *Gray Level Run Length Matrix* (GALLOWAY, 1975) e índices de diversidade como o índice de Shannon (SHANNON, 2001) ou o índice de McIntosh (MCINTOSH, 1967) em conjunto com as técnicas baseadas em padrões locais.
5. Utilizar outra base de imagens;

Referências

- ACS. *Learn About Breast Cancer*. 2015. Available at <http://www.cancer.org>, last accessed February 4, 2012. Citado na página 14.
- AHMED, F.; HOSSAIN, E.; BARI, A.; SHIHAVUDDIN, A. Compound local binary pattern (clbp) for robust facial expression recognition. In: IEEE. *Computational Intelligence and Informatics (CINTI), 2011 IEEE 12th International Symposium on*. Obuda University, Budapest, Hungary, 2011. p. 391–395. Citado 3 vezes nas páginas 6, 21 e 22.
- BOVIK, A. C.; CLARK, M.; GEISLER, W. S. Multichannel texture analysis using localized spatial filters. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, IEEE, v. 12, n. 1, p. 55–73, 1990. Citado na página 17.
- CHANG, C.-C.; LIN, C.-J. Libsvm: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology (TIST)*, ACM, v. 2, n. 3, p. 27, 2011. Citado na página 31.
- CHAVES, A. d. C. F. *Extração de Regras Fuzzy para Máquinas de Vetores Suporte (SVM) para Classificação em Múltiplas Classes*. Tese (Doutorado) — PUC-Rio, 2006. Citado na página 23.
- DUARTE, Y. A.; NASCIMENTO, M. Z. do; OLIVEIRAS, D. L. Algoritmo de extração de textura baseado em wavelet e clbp para classificação de lesões em mamogramas. In: SOCIEDADE BRASILEIRA DE COMPUTAÇÃO (SBC). *XIII Workshop de Informática Médica*. Maceió, AL, 2013. p. 174–183. Citado na página 14.
- GALLOWAY, M. M. Texture analysis using gray level run lengths. *Computer graphics and image processing*, Elsevier, v. 4, n. 2, p. 172–179, 1975. Citado na página 41.
- GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*. Upper Saddle River, NJ, USA: Pearson Prentice Hall, 2006. Citado na página 17.
- GUO, Z.; ZHANG, L.; ZHANG, D. A completed modeling of local binary pattern operator for texture classification. *Image Processing, IEEE Transactions on*, IEEE, v. 19, n. 6, p. 1657–1663, 2010. Citado na página 14.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. H. Textural features for image classification. *Systems, Man and Cybernetics, IEEE Transactions on*, IEEE, n. 6, p. 610–621, 1973. Citado na página 41.
- HEATH, M.; BOWYER, K.; KOPANS, D.; MOORE, R.; KEGELMEYER, W. P. The digital database for screening mammography. In: CITESEER. *Proceedings of the 5th international workshop on digital mammography*. Rochester, NY, 2000. p. 212–218. Citado na página 26.
- HEIKKILÄ, M.; PIETIKÄINEN, M.; SCHMID, C. Description of interest regions with center-symmetric local binary patterns. In: *Computer Vision, Graphics and Image Processing*. San Diego, CA, USA: Springer, 2006. p. 58–69. Citado 3 vezes nas páginas 6, 20 e 21.

- INCA. Estimativas 2014: Incidência de câncer no Brasil. Acessado em 8 de Março de 2016. 2014. Disponível em: <<http://www.inca.gov.br/estimativa/2014/>>. Citado 2 vezes nas páginas 13 e 14.
- INCA. O câncer de mama. Acessado em 14 de Março de 2016. 2015. Disponível em: <<http://www.inca.gov.br/wcm/outubro-rosa/2015/cancer-de-mama.asp>>. Citado 3 vezes nas páginas 4, 5 e 13.
- JUNIOR, G. B. *Classificação de Regiões de Mamografias em Massa e Não Massa usando Estatística Espacial e Máquina de Vetores de Suporte*. Dissertação (Mestrado) — Universidade Federal do Maranhão, 2008. Citado na página 26.
- LIM, W. K.; ER, M. J. Classification of mammographic masses using generalized dynamic fuzzy neural networks. *Medical physics*, American Association of Physicists in Medicine, v. 31, n. 5, p. 1288–1295, 2004. Citado na página 14.
- LUMINI, L. N. S. B. A. Selecting the best performing rotation invariant patterns in local binary/ternary patterns. In: CITESEER. *International conference on IP, computer vision, and pattern recognition*. Las Vegas, Nevada, USA, 2010. Citado na página 19.
- MCINTOSH, R. P. An index of diversity and the relation of certain concepts to diversity. *Ecology*, JSTOR, p. 392–404, 1967. Citado na página 41.
- MURAMATSU, C.; ZHANG, M.; HARA, T.; ENDO, T.; FUJITA, H. Differentiation of malignant and benign masses on mammograms using radial local ternary pattern. In: *Breast Imaging*. Gifu City, Japan: Springer, 2014. p. 628–634. Citado na página 14.
- NANNI, L.; BRAHNAM, S.; LUMINI, A. A very high performing system to discriminate tissues in mammograms as benign and malignant. *Expert Systems with Applications*, Elsevier, v. 39, n. 2, p. 1968–1971, 2012. Citado na página 14.
- NANNI, L.; LUMINI, A.; BRAHNAM, S. Survey on lbp based texture descriptors for image classification. *Expert Systems with Applications*, Elsevier, v. 39, n. 3, p. 3634–3641, 2012. Citado 3 vezes nas páginas 6, 19 e 20.
- NASSEER, M.; MUSTAFA, H. Classification of breast masses in digital mammograms using support vector machines. *International Journal of Advanced Research in Computer Science and Software Engineering*, v. 3, n. 10, p. 57–63, 2013. Citado na página 15.
- OJALA, T.; PIETIKÄINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*, Elsevier, v. 29, n. 1, p. 51–59, 1996. Citado na página 18.
- OJALA, T.; PIETIKÄINEN, M.; MÄENPÄÄ, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, IEEE, v. 24, n. 7, p. 971–987, 2002. Citado 2 vezes nas páginas 6 e 18.
- OJANSIVU, V.; HEIKKILÄ, J. Blur insensitive texture classification using local phase quantization. In: *Image and signal processing*. Gifu City, Japan: Springer, 2008. p. 236–243. Citado na página 14.

OLIVER, A.; LLADÓ, X.; FREIXENET, J.; MARTÍ, J. False positive reduction in mammographic mass detection using local binary patterns. *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2007*, Springer, p. 286–293, 2007. Citado na página 15.

RANDEN, T.; HUSOY, J. H. Filtering for texture classification: A comparative study. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, IEEE, v. 21, n. 4, p. 291–310, 1999. Citado na página 18.

ROCHA, S. V. da. *Diferenciação do Padrão de Malignidade e Benignidade de Massas em Imagens de Mamografias Usando Padrões Locais Binários, Geoestatística e Índices de Diversidade*. Tese (Doutorado) — Universidade Federal do Maranhão, 2014. Citado 5 vezes nas páginas 6, 19, 23, 24 e 31.

SHANNON, C. E. A mathematical theory of communication. *ACM SIGMOBILE Mobile Computing and Communications Review*, ACM, v. 5, n. 1, p. 3–55, 2001. Citado na página 41.

STEWART, B. W.; WILD, C. P. et al. *World cancer report 2014*. Lyon, France: IARC Press, International Agency for Research on Cancer, 2014. Citado 2 vezes nas páginas 12 e 13.

TUCERYAN, M.; JAIN, A. K. et al. Texture analysis. *Handbook of pattern recognition and computer vision*, v. 2, p. 207–248, 1993. Citado na página 18.

VAPNIK, V. *The nature of statistical learning theory*. New York, NY, USA: Springer Science & Business Media, 2013. Citado 3 vezes nas páginas 22, 23 e 24.