

Gustavo Alves Reche

**Análise do comportamento do descritor de
textura *Local Mapped Pattern* na classificação
de distorção arquitetural mamária em imagens
mamográficas**

São Carlos, Brasil

2017

Gustavo Alves Reche

Análise do comportamento do descritor de textura *Local Mapped Pattern* na classificação de distorção arquitetural mamária em imagens mamográficas

Trabalho de Conclusão de Curso apresentado à Escola de Engenharia de São Carlos, da Universidade de São Paulo. Curso de Engenharia Elétrica com ênfase em Eletrônica

Orientador: Prof. Dr. Marcelo Andrade da Costa Vieira

São Carlos, Brasil

2017

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pela Biblioteca Prof. Dr. Sérgio Rodrigues Fontes e
Seção Técnica de Informática, EESC/USP com os dados fornecidos pelo(a) autor(a).

R296a Reche, Gustavo Alves
Análise do comportamento do descritor de textura
Local Mapped Pattern na classificação de distorção
arquitetural mamária em imagens mamográficas / Gustavo
Alves Reche; orientador Marcelo Andrade da Costa
Vieira. São Carlos, 2017.

Monografia (Graduação em Engenharia Elétrica com
ênfase em Eletrônica) -- Escola de Engenharia de São
Carlos da Universidade de São Paulo, 2017.

1. LMP. 2. DAM. 3. Classificador. 4. Mamografia. 5.
Textura. 6. Imagem. I. Título.

Bibliotecário responsável pela estrutura de catalogação da publicação:

Eduardo Graziosi Silva - CRB - 8/8907

FOLHA DE APROVAÇÃO

Nome: Gustavo Alves Reche

Título: "Análise do comportamento do descritor de textura Local Mapped Pattern na classificação de distorção arquitetural mamária em imagens mamográficas"

Trabalho de Conclusão de Curso defendido e aprovado
em 01/12/2017,

com NOTA 9,5 (NOVE, CINCO), pela Comissão Julgadora:

Prof. Dr. Marcelo Andrade da Costa Vieira - Orientador - SEL/EESC/USP

Prof. Associado Adilson Gonzaga - SEL/EESC/USP

Mestre Tamiris Trevisan Negri - Doutoranda - SEL/EESC/USP

Coordenador da CoC-Engenharia Elétrica - EESC/USP:
Prof. Associado Rogério Andrade Flauzino

Este trabalho é dedicado aos meus pais e avós, que possam ver nesse trabalho o fruto da dedicação dada aos seus filhos e uma forma de retorno a todo o esforço realizado para nossa formação.

Agradecimentos

Os agradecimentos principais vão a todos que me apoiaram no caminho para a minha formação na USP. Meus pais, avós, amigos e todos que sempre estiveram comigo nessa jornada.

Um agradecimento em especial ao professor Marcelo e ao Helder pelas longas e proveitosas conversas sobre esse TCC.

Resumo

Um dos grandes objetivos da mamografia digital é a detecção do câncer de mama em seus estágios iniciais. Com o auxílio de sistemas computacionais como o CAD (*Computer Aided Detection*), o radiologista faz a análise de mamografias para diagnosticar a presença de nódulos, de microcalcificações ou de distorção arquitetural mamária (DAM), os quais representam a presença de câncer em desenvolvimento. Como a DAM é o primeiro indicativo de tecido cancerígeno, é interessante que ela seja diagnosticada com eficácia. Infelizmente, a sua detecção por radiologistas com a ajuda dos sistemas CAD ocorre em menos de 50% dos casos. A grande dificuldade da detecção da distorção arquitetural reside no fato de ser uma contração bastante sutil do tecido mamário, na qual não há borda definida e, na maioria dos casos, não existe qualquer formação de massa associada. Sua detecção por meio dos métodos computacionais propostos na literatura se dá por meio do uso de descritores de textura e métodos de classificação como as redes neurais. A baixa taxa de detecção pode ser atribuída ao fato de os descritores de texturas utilizados não serem robustos, como por exemplo, os descritores baseados nas matrizes de co-ocorrência propostas por Haralick. Desse modo, se faz necessário a utilização de um descritor de textura que seja mais eficiente, que possa descrever melhor esse tipo de anomalia, como o LMP (*Local Mapped Pattern*). O LMP é um descritor paramétrico, por conta da função *Sigmoidal*, que permite que sua inclinação possa ser ajustada, por meio de técnicas de otimização, de modo a obter um melhor resultado de acordo com o problema a ser resolvido. Nesse sentido esse trabalho propõe a utilização do descritor de texturas LMP otimizado para detecção e identificação de distorção arquitetural mamária em imagens de mamografia. Com isso, podem-se distinguir as imagens que possuem e as que não possuem DAM automaticamente, sem a necessidade de releitura da imagem pelo médico radiologista. Isso se traduz em diagnósticos mais eficientes e rápidos, o que ajuda no diagnóstico precoce do câncer de mama, possibilitando um tratamento mais efetivo. Os resultados mostraram que a utilização de um β fixo para a entrada do descritor de textura LMP é a escolha mais eficiente e atrativa.

Palavras-chave: Mamografia. Distorção Arquitetural Mamária. LMP.

Abstract

One of the greatest challenges in digital mammography is the detection of breast cancer in its initial stages. With the help of computational systems such as CAD (*Computer Aided Detection*), the radiologist analyzes the mammogram in order to diagnose the presence of nodules, microcalcifications or architectural distortion, which are elements that indicate the presence of cancerous tissue. As architectural distortion is the first sign of cancer, it is of major importance that it gets identified efficiently. Unfortunately, the detection made by radiologists with the help of CAD systems occurs in less than 50% of the cases. The big challenge in detecting architectural distortion rests on the fact that it is a very subtle contraction of the breast tissue, with no defined borders and in most cases, no presence of associated formation of mass. Its detection using computational methods proposed in literature has to do with texture descriptors and methods of classification such as neural networks. The low detection rate can be associated with the fact that the used texture descriptors are not sturdy, such as the texture descriptors based on the co-occurrence matrix proposed by Haralick. In that way, the use of an even more efficient texture descriptor is needed, one that can describe better this kind of anomaly, such as the LMP (*Local Mapped Pattern*). LMP is a parametric descriptor, due to the *Sigmoidal* function, that allows its slope to be adjusted using optimization techniques, in order to obtain a better result in accordance to the problem to be solved. In that sense, this work proposes the use of LMP texture descriptor to the detection and identification of architectural distortion in mammograms. With that, the images which possess architectural distortion and those that do not, can be distinguished without the need of a second reading of the image by the radiologist. That is translated into quicker and more efficient diagnoses, making its way to the early detection of breast cancer and more effective treatments. The results show that using a constant β for all the images as the input of the LMP texture descriptor is the most efficient and computationally attractive choice.

Keywords: Mammography. Architectural Distortion. LMP.

Lista de abreviaturas e siglas

AM	Aprendizado de Máquina
CAD	Computer Aided Detection
DAM	Distorção Arquitetural Mamária
DDSM	Digital Database Screening Mammography
FFDM	Full Field Digital Mammography
FN	<i>False negative</i>
FP	<i>False Positive</i>
INCA	Instituto Nacional do Câncer
KNN	<i>K-Nearest Neighbour</i>
LAVI	Laboratório de Visão Computacional
LBP	<i>Local Binary Pattern</i>
LMP	<i>Local Mapped Pattern</i>
MAD	<i>Desvio Médio Absoluto</i>
ROI	<i>Regions of Interest</i>
SIM	Sistema de Informações sobre Mortalidade
SRM	<i>Structural Risk Minimization</i>
SVM	<i>Support Vector Machines</i>
TAE	Teoria do Aprendizado Estatístico
TN	<i>True Negative</i>
TP	<i>True Positive</i>

Sumário

1	INTRODUÇÃO	17
1.1	Contextualização	17
1.2	Justificativa	18
1.3	Objetivos	19
1.4	Formato do Trabalho	20
2	FUNDAMENTAÇÃO TEÓRICA	21
2.1	Câncer de Mama/Mamografia	21
2.2	Distorção Arquitetural Mamária	22
2.3	Descritores de textura	22
2.4	<i>Local Binary Pattern</i> (LBP)	23
2.5	<i>Local Mapped Pattern</i> (LMP)	25
2.6	Máquinas de Vetores de Suporte (SVMs, do inglês <i>Support Vectors Machine</i>)	26
2.6.1	Aprendizado de Máquina (AM)	26
2.6.2	Teoria do Aprendizado Estatístico	27
2.6.3	Máquinas de Vetores de Suporte Lineares com Margens Rígidas	28
2.6.4	Máquinas de Vetores de Suporte Lineares com Margens Suaves	29
2.6.5	Máquinas de Vetores de Suporte Não-Lineares	30
3	MATERIAIS E MÉTODOS	32
3.1	Materiais	32
3.1.1	Detecção de Distorção Arquitetural Mamária	32
3.1.2	Imagens de Mamografia Digitalizadas	32
3.2	Métodos	34
3.2.1	Acurácia	34
3.2.2	Extração das Características da Imagem	35
3.2.3	Utilização de β fixo	35
3.2.4	Utilização de β dependente da imagem e separação das imagens por mediana	35
3.2.5	Classificação de uma imagem através da escolha de β segundo a imagem a ser classificada e utilização de tal valor β na descrição do conjunto de treinamento	38
3.2.6	Classificador	39
3.2.7	MATLAB	39

4	RESULTADOS E DISCUSSÕES	40
4.1	Utilização de β fixo	40
4.2	Utilização de β dependente da imagem e separação das imagens por mediana	44
4.3	Análise das consequências da utilização de diferentes β s para cada imagem	49
4.3.1	Utilização de β fixo para o grupo de treinamento e para uma imagem	54
5	CONCLUSÃO	61
6	CONTRIBUIÇÃO E TRABALHOS FUTUROS	63
	REFERÊNCIAS	64

1 Introdução

1.1 Contextualização

O câncer de mama é uma mutação anormal das células mamárias, que causa a formação de um tumor maligno na região das mamas. Acometendo em sua maioria mulheres, o câncer de mama tem sido um dos assuntos mais pautados pelas organizações de saúde, dadas suas consequências e altos índices de incidência.

Uma das grandes esperanças no combate ao câncer de mama é sua detecção em estágios iniciais. Tal condição permite ao médico uma maior expectativa no tratamento, sendo que as chances de cura podem aumentar em até 30% em relação ao tratamento em estágios avançados, o qual possui baixos índices de cura ([ELMORE et al., 2003](#)).

Os principais métodos para o diagnóstico do câncer de mama consistem em exames de ultrassonografia, ressonância magnética e a mamografia digital de campo total (FFDM - Full Field Digital Mammography), o qual é o exame mais utilizado no mundo todo ([KARELLAS; VEDANTHAM, 2008](#)).

A mamografia consiste na utilização de raios X para impressão da estrutura mamária em um filme. Na imagem formada, pode-se observar os contrastes entre os tecidos de diferentes densidades, permitindo uma análise de deformações teciduais, característico do câncer, sem a necessidade de realização de um método mais invasivo, como a biópsia.

O exame mamográfico também permite um diagnóstico prévio da presença de câncer, o qual se dá pelo aparecimento de três deformações. São eles os nódulos, as microcalcificações e a Distorção Arquitetural Mamária (DAM). Os dois primeiros são estruturas que apresentam a formação de massa associada, enquanto a Distorção Arquitetural Mamária é caracterizada pela deformação sutil do tecido da mama.

A Distorção Arquitetural Mamária é o indício mais precoce do câncer de mama, sendo o achado mais comum em exames retrospectivos ([GAUR et al., 2013](#)). A DAM pode surgir antes mesmo da formação de microcalcificações e nódulos, sendo uma deformação de difícil detecção ([GAUR et al., 2013](#)). Não possuindo borda definida, ela é classificada como achado suspeito, sendo de difícil classificação até mesmo por um radiologista experiente ([RAY et al., 2015](#)).

Para auxiliar na detecção precoce do câncer de mama os sistemas CAD, ou Sistemas Computacionais de Auxílio à Detecção, fornecem uma segunda opinião ao radiologista ([DEAN; ILVENTO, 2006](#)) Mas, mesmo com tal auxílio, o desempenho na detecção de Distorção Arquitetural ainda é baixo, com taxas de detecção abaixo dos 50% ([BAKER et](#)

al., 2003). Tais taxas mostram-se insatisfatórias para o efetivo diagnóstico precoce dos inúmeros casos de câncer de mama que ocorrem a cada ano no Brasil.

1.2 Justificativa

A Distorção Arquitetural Mamária caracteriza-se por uma alteração sutil na textura da mama, detectada na mamografia. Tal fato, permite a utilização de descritores de textura para detecção automática da presença de DAM.

A taxa de detecção do CAD é baixa por utilizar descritores de textura pouco robustos e não baseados em micropadrões locais, que não conseguem detectar a Distorção Arquitetural Mamária de forma satisfatória. Soma-se a isso a característica da DAM ser uma contração sutil do tecido mamário sem possuir uma borda definida e sem formação de massa associada.

Para os métodos de detecção já existentes de DAM como os sistemas CAD, os detectores de textura mais empregados são mais antigos, como as matrizes de coocorrência de Haralick (JASIONOWSKA; PRZELASKOWSKI, 2010) operadores morfológicos (KAMRA; JAIN, 2013) dentre outras técnicas (BANIK; RANGAYYAN; DESAUTELS, 2013), o que deixa a detecção menos precisa e com menor acurácia. Diversos novos detectores de textura poderiam ser testados na detecção de DAM, onde muitos deles têm apresentado maior capacidade de descrição de tecidos mais específicos.

Um dos descritores de textura mais utilizados da atualidade para as mais diversas aplicações é o LBP (*Local Binary Pattern*) (OJALA; PIETIKAINEN; HARWOOD, 1996) (OJALA; PIETIKAINEN; MAENPAA, 2002). Esse descritor têm sido muito utilizado devido à sua alta capacidade de descrição, sua simplicidade e seu baixo custo computacional. Porém, mesmo sendo largamente utilizado, o LBP possui diversas limitações, dentre elas a incapacidade de poder descrever propriamente texturas mais complexas. Essa limitação se deve ao fato de sua função de mapeamento ser a função degrau (*Heavyside*).

Com o objetivo de superar as limitações do LBP, foi desenvolvido no Laboratório de Visão Computacional (LAVI), o descritor LMP (*Local Mapped Pattern*) (VIEIRA et al., 2012) (FERRAZ et al., 2014). O LMP traz consigo a mesma qualidade do conhecido descritor LBP, adicionado a uma maior capacidade de descrição, possibilitando a troca da função de mapeamento de *Heavyside* para uma função qualquer, sendo a função *Sigmoidal* a mais utilizada.

O LMP ao utilizar a função *Sigmoidal* se torna um descritor paramétrico, que permite que sua inclinação possa ser ajustada, por meio de técnicas de otimização. O parâmetro que indica a inclinação da curva sigmoideal é representado pela letra grega β , a qual deve ser otimizada para uma melhor descrição da textura a ser analisada.

Nos trabalhos (OLIVEIRA et al., 2017) e (OLIVEIRA et al., 2016), desenvolvidos no Laboratório de Visão Computacional (LAVI) da Universidade de São Paulo de São Carlos, encontrou-se uma acurácia na utilização do LMP para a classificação de DAM em imagens de mamografia superior ao LBP e aos quatro parâmetros de Haralick, indicando uma melhor caracterização dessa deformidade no tecido pelo LMP. Em diversos outros trabalhos o LMP também tem se mostrado superior aos outros tipos de descritores, como as matrizes de co-ocorrência de Haralick, na descrição de diversos tipos de textura (VIEIRA et al., 2012) (CHIERICI et al., 2013) (FERRAZ et al., 2014) (FERRAZ; PEREIRA; GONZAGA, 2014b) (FERRAZ; PEREIRA; GONZAGA, 2014a) (NEGRI; GONZAGA, 2014).

Todos esses estudos levam a crer que o correto emprego do descritor de textura LMP na análise de presença de DAM em mamografias pode otimizar as taxas de detecção do câncer em estágios iniciais, em comparação com os outros descritores de textura, já utilizados na literatura. Porém, pelo LMP ser um descritor paramétrico, o seu correto uso depende do treinamento do seu parâmetro de entrada β , o que faz com que a taxa de acertos e o custo computacional de tal tarefa tenha de ser levada em conta.

1.3 Objetivos

O parâmetro β da curva sigmóide do *Local Mapped Pattern* indica a inclinação da curva e a escolha do seu valor implica na alteração da performance do descritor de textura. Uma forma intuitiva da escolha do β é selecionar uma faixa de valores e testar todos os β s dentro dessa faixa. Aquele β para o qual o descritor obtém maior sucesso é o melhor valor possível, dentro daquela faixa.

A utilização de tal método implica em um custo computacional muito grande e pode ser que a escolha de um β fixo para todas as imagens não seja a melhor hipótese. Faz-se então necessário encontrar um método de escolha para o valor do β automatizado, sem a necessidade de testes extensivos e uma possibilidade é relacionar tal parâmetro com as características da imagem.

Na esperança de automatizar o processo de escolha do parâmetro do descritor de texturas LMP, esse trabalho tem por objetivo analisar a relação entre as características da imagem e o β ótimo, permitindo a correta e mais precisa classificação de uma área da imagem de mamografia na análise da Distorção Arquitetural. Também são comparadas as performances do LBP com o LMP.

O ajuste de β dependendo das características da imagem eliminaria a necessidade de treinamento do valor da inclinação da curva sigmoide e implicaria numa redução muito grande do custo computacional na classificação de uma imagem mamográfica.

1.4 Formato do Trabalho

Este trabalho conta com cinco capítulos, como listado a seguir.

- Capítulo 1 – Introdução: apresenta uma introdução sobre o tema abordado nesse trabalho.
- Capítulo 2 – Fundamentação teórica: introduz conceitos importantes para o entendimento de tudo que é discutido nesse trabalho, como o descritor de textura LMP e os classificadores.
- Capítulo 3 – Materiais e Métodos: explica a metodologia abordada nesse trabalho.
- Capítulo 4 – Resultados: apresenta os resultados encontrados para a otimização do LMP.
- Capítulo 5 – Conclusões: análise dos resultados obtidos nesse trabalho e da sua praticidade, comparação com métodos já presentes na literatura.
- Capítulo 6 – Contribuição e Trabalhos Futuros

2 Fundamentação Teórica

Aqui se apresentam alguns conceitos básicos para o entendimento desse trabalho. Conceitos como a distorção arquitetural, o descritor de textura LMP e o SVM (*Support Vector Machines*) são explicados.

2.1 Câncer de Mama/Mamografia

O câncer de mama é o segundo câncer mais comum entre as mulheres do mundo e do Brasil, atrás apenas do câncer de pele não melanoma (INCA..., 2017). Em 2013 o número de mortes devido a tal câncer foi de 14.388, sendo 181 homens e 14.206 mulheres (SIM..., 2017). Estima-se que em 2016 tenham ocorridos 57.960 novos casos (INCA..., 2017).

O câncer de mama é uma multiplicação anormal das células mamárias, sem origem ou causa definido e caracterizado, principalmente, pelo aparecimento de nódulo na região afetada. Sem possuir uma origem certa, diversos fatores podem se relacionar com o aparecimento do câncer de mama, dentre eles a obesidade após a menopausa, o sedentarismo, o consumo de bebida alcoólica e a exposição frequente a radiações ionizantes, além de fatores da história reprodutiva e hormonal e fatores genéticos e hereditários (INCA..., 2017). Não acometendo somente mulheres, cerca de 1% dos casos são diagnosticados em homens (INCA..., 2017).

Apesar da origem incerta do câncer de mama, diversas medidas preventivas são indicadas. Em pacientes com grande propensão genética, como a presença de diversos casos familiares, a retirada da mama é uma opção. O controle dos fatores de riscos conhecidos possibilita uma redução de 28% na chance da paciente desenvolver câncer de mama no Brasil. Estimula-se, portanto a prática regular de exercícios físicos, a manutenção do peso corporal, a adoção de uma alimentação mais saudável e a redução do consumo de bebidas alcoólicas.

Medidas preventivas muitas vezes não são suficientes para prevenir a aparição do câncer de mama, faz-se necessário então, um diagnóstico preliminar prévio ao aparecimento de nódulos ou de massas palpáveis, para futuro tratamento dessa condição. O diagnóstico por imagem permitiu a utilização de métodos não invasivos para diagnóstico da doença em estágios iniciais.

A primeira mamografia (utilização de Raios X para análise de tecidos internos da mama) foi feita por Albert Salomon em 1913 e permitiu a identificação de pequenos pontos suspeitos na mama, denominados de microcalcificações (GOLD; BASSET, 1990).

A partir daí métodos cada vez mais elaborados e técnicas de posicionamento da mama permitiram a identificação cada vez mais precisa da presença de tecidos cancerígenos.

A análise de mamografias prévias de pacientes com câncer de mama permitiu a delimitação de três fases do desenvolvimento do tecido cancerígeno. Previamente à observação de massa associada, observa-se a Distorção Arquitetural Mamária (DAM), uma contração bastante sutil do tecido, onde não há borda definida. Segue-se ao DAM a presença de nódulos e posteriormente de microcalcificações, onde há formação de massa associada.

A distinção entre presença ou não de nódulos, microcalcificações e DAM é realizada por um médico radiologista com o auxílio de sistemas computacionais como o CAD (*Computer Aided Detection*). Em questões de eficiência, foi comprovado que o radiologista com a ajuda dos sistemas CAD, consegue detectar até 90% das microcalcificações e nódulos nas mamografias, enquanto que a detecção da DAM ocorre em menos de 50% dos casos (BAKER et al., 2003).

2.2 Distorção Arquitetural Mamária

DAM é de difícil detecção nos exames de mamografia convencional, pois não possui borda bem definida e não ocorre a formação de massa visível. Dessa forma, mesmo o radiologista mais experiente pode não ser capaz de identificá-la (RAY et al., 2015)

Normalmente, a DAM é considerada um achado suspeito (D'ORSI, 2011), onde apenas a biópsia pode descartar a hipótese de malignidade. É o acontecimento mais comum na análise de exames retrospectivos de pacientes com diagnóstico de câncer tardio.

Com o intuito de aumentar os índices de acerto na detecção do câncer de mama, os CADs são normalmente utilizados na prática clínica. Esses softwares fornecem uma “segunda opinião” ao médico radiologista (DEAN; ILVENTO, 2006) (YANG et al., 2007).

A detecção de microcalcificações e nódulos é alta, quando assistida pelos sistemas CAD, cerca de 90% dos casos. Já para a detecção de DAM, esse número cai para 50% dos casos. (BAKER et al., 2003).

O padrão textural comum da mama parte do músculo peitoral e converge no mamilo. Se esse padrão é distorcido sem que haja presença de nódulos ou microcalcificações é provável que se tenha uma Distorção Arquitetural.

2.3 Descritores de textura

O processamento digital de imagens permite que inúmeras tarefas sejam realizadas automaticamente, desde o reconhecimento de caracteres até a detecção facial e de mo-

vimentos. A descrição de texturas em uma imagem entra como uma forma de detectar padrões locais de forma rápida e automática, que quando identificados, podem atestar a presença de alguma doença, como no caso da mamografia.

Texturas são padrões visuais complexos, compostos de subpadrões que possuem características específicas, dentre luminosidade, cor e tamanho por exemplo (MATERKA; STRZELECKI, 1998). Logo, a textura pode ser definida como um agrupamento de similaridades em uma imagem (ROSENFELD; KAK, 1982).

Os descritores de textura são algoritmos que trazem as características de uma imagem de forma numérica, descrevendo as suas propriedades visíveis. Esse conjunto de técnicas, que compreendem os descritores de textura, podem ser divididos em três grandes grupos: estatístico, estrutural e espectral (GONZALEZ; WOODS, 2008).

O conjunto estrutural representa a textura por primitivas muito bem definidas (microtextura) e arranjos espaciais hierarquizados (macrotextura) dessas primitivas (MATERKA; STRZELECKI, 1998). Mostrou-se útil na detecção de mudanças na microestrutura de ossos.

Diferentemente dos métodos estruturais, os métodos estatísticos tentam representar a textura pelas relações entre os níveis de cinza de uma imagem. O mais conhecido descritor de textura estatístico é derivado das chamadas matrizes de coocorrência de Haralick, os quais demonstraram um grande potencial na descrição de imagens biomédicas.

Métodos espectrais, como Fourier, Gabor e as Transformadas Wavelet, representam a imagem em um espaço diferente, onde os novos eixos relacionados têm uma interpretação relacionada com as características específicas da imagem (como frequência).

Diferentes descritores de textura têm eficiências diferentes para texturas específicas. No presente caso, com o tratamento de imagens biomédicas, os descritores estatísticos mostraram melhor performance diversas vezes (LERSKI et al., 1993) (STRZELECKI, 1995) e por isso eles são investigados aqui.

2.4 Local Binary Pattern (LBP)

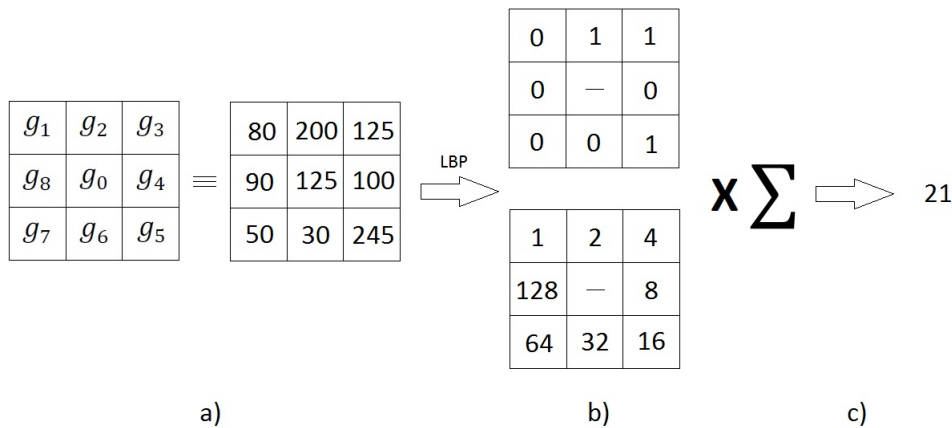
O descritor de texturas estatístico LBP tem se mostrado superior a diversos outros descritores de textura (AHONEN; HADID; PIETIKAINEN, 2006). Isso se deve a sua resistência à iluminação, baixa complexidade computacional e capacidade em descrever detalhes finos (LORIS; ALESSANDRA; SHERYL, 2012). Na medicina, por exemplo, ele tem sido usado para identificar células mamárias cancerígenas (OLIVER et al., 2007) e como um detector de textura da extração de cortes da tireóide (KERAMIDAS et al., 2008).

Ele foi proposto pela primeira vez em (OJALA; PIETIKAINEN; HARWOOD, 1996) e a ideia básica por trás do LBP é que a imagem é composta por micropadrões. O

operador LBP convencional extrai informações que são invariantes a variações em escalas de cinza locais e à rotação da imagem.

Considere uma vizinhança 3×3 da imagem definida como na Figura 1a. O pixel central é comparado com todos os pixels à sua volta. Se o pixel sendo analisado for maior do que o pixel central troca-se o seu valor por 1 e 0 caso contrário. Aplicando tal lógica na Figura 1a, obtém-se então a Figura 1b, onde a matriz de baixo corresponde aos pesos que serão dados a cada pixel. Após a multiplicação dos valores pelos pesos, soma-se o valor total, obtendo o novo valor que substituirá o pixel central.

Figura 1 – Aplicação do LBP em uma vizinhança 3×3 . A vizinhança em a) tem os pixels vizinhos comparados com o pixel central e trocados por 1 se seu valor for maior ou igual ao pixel central e 0 caso contrário. Os valores obtidos são multiplicados pela matriz de pesos em b) e somados, obtendo na operação c) o valor final que substituirá o pixel central.



Fonte: autoria própria

Na Figura 1 a passagem do a) para o b) é representado abaixo pela utilização da função de HeavySide $S()$ e de uma matriz de pesos 2^{i-1} . A parte c) da imagem representa a multiplicação e posterior soma desses dois fatores. Esses passos se encontram resumidos na Equação 2.1.

$$LBP = \sum_{i=1}^8 S(g_0, g_i) 2^{i-1}, \quad S(g_0, g_i) = \begin{cases} 1, & \text{if } [g_i - g_0] \geq 0 \\ 0, & \text{if } [g_i - g_0] < 0 \end{cases} \quad (2.1)$$

Na abordagem do LBP a diferença entre os níveis de cinza para uma vizinhança de 256 bins é mapeada. Esta formulação é limitada a uma janela de 3×3 pixels, com número de bins fixo, daí uma de suas limitações.

Porém, mesmo sendo largamente utilizado, o LBP possui outras limitações, dentre elas a incapacidade de poder descrever propriamente texturas mais complexas. Essa

limitação se deve ao fato de sua função de mapeamento ser a função degrau (*Heavyside*).

Com o objetivo de superar as limitações do LBP, foi desenvolvido no Laboratório de Visão Computacional (LAVI), o descritor LMP (*Local Mapped Pattern*). O LMP traz consigo a mesma qualidade do conhecido descritor LBP, adicionado a uma maior capacidade de descrição e possibilitando a troca da função de mapeamento de *Heavyside* por uma função qualquer, sendo a função *Sigmoidal* a mais utilizada.

2.5 Local Mapped Pattern (LMP)

O LBP faz uso da função binária, enquanto o LMP permite utilizar qualquer função de mapeamento. Essa funcionalidade maleável do LMP tem gerado resultados superiores na classificação de tipos de texturas dos mais variados, como texturas coloridas, rotacionadas e com variações de iluminação (VIEIRA et al., 2012) (CHIERICI et al., 2013) (FERRAZ et al., 2014) (FERRAZ; PEREIRA; GONZAGA, 2014b) (FERRAZ; PEREIRA; GONZAGA, 2014a) (NEGRI; GONZAGA, 2014).

Na tentativa de expandir o uso do LBP para uma vizinhança genérica de $W \times W$ pixels, para um histograma de B bins, decidiu-se equacionar o LBP com uma matriz de pesos binários $P(i)$, segundo as equações abaixo, onde $w = (W \times W) - 1$.

$$P(i) = \begin{bmatrix} 1 & 2 & 4 \\ 128 & 0 & 8 \\ 64 & 32 & 16 \end{bmatrix} \quad (2.2)$$

$$LMP = \text{round} \left(\frac{\sum_{i=1}^w f_g \cdot P(i)}{\sum_{i=1}^w P(i)} (B - 1) \right) \quad (2.3)$$

$$f_g = H[g_i - g_0] = \begin{cases} 1, & \text{if } [g_i - g_0] \geq 0 \\ 0, & \text{if } [g_i - g_0] < 0 \end{cases} \quad (2.4)$$

Diz-se que a função f_g , ou função de *Heavyside* é a “função de mapeamento”. Essa nova abordagem recebeu o nome de *Local Mapped Pattern* (LMP), o que se caracteriza, na verdade, como uma generalização do método LBP para uma função de mapeamento que pode ser variada, assim como a matriz de pesos. Assim, a função de mapeamento pode ser alterada de acordo com o problema sendo estudado. Se utilizarmos a matriz de pesos como na [Equação 2.5](#) e a função sigmoidal como na [Equação 2.6](#):

$$P(i) = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (2.5)$$

$$f_g = \frac{1}{1 + e^{-\frac{[g_i - g_0]}{\beta}}} \quad (2.6)$$

obtém-se a [Equação 2.7](#):

$$h_b = \text{round} \left(\frac{\sum_{i=1}^w \left(\frac{1}{1 + e^{-\frac{[g_i - g_0]}{\beta}}} P(i) \right)}{\sum_{i=1}^w P(i)} (B - 1) \right) \quad (2.7)$$

Com tal formulação, uma maior mobilidade é possível para cada problema. O número de *bins* pode ser modificado, variando-se o parâmetro B, assim como o parâmetro β pode ser variado, o qual define a inclinação da curva de mapeamento. Essa mobilidade permite uma maior aplicação do descritor LMP, como será feita para detecção da DAM.

2.6 Máquinas de Vetores de Suporte (SVMs, do inglês *Support Vectors Machine*)

As Máquinas de Vetores de Suporte, ou *Support Vector Machines* (SVMs), são uma técnica de Aprendizado de Máquina. Muito utilizadas para reconhecimento de caracteres escritos à mão, as SVM são uma técnica com boa capacidade de generalização, robustez em grandes dimensões e com um embasamento teórico forte (SMOLA et al., 1999). Ao contrário das redes neurais, as SVMs são uma técnica determinística e por isso não correm o risco de caírem em mínimos locais.

Essa técnica foi desenvolvida por Vapnik e colaboradores (CORTES; VAPNIK, 1995), tendo como base a Teoria de Aprendizado Estatístico (TAE) (VAPNIK, 1995) e o princípio de Minimização do Risco Estrutural (SRM, em inglês *Structural Risk Minimization*) (CHERVONENKIS; VAPNIK, 1974).

Nesta seção, são introduzidas as principais definições para o correto entendimento das SVMs, tais como o conceito de Aprendizado de Máquina e da TAE.

2.6.1 Aprendizado de Máquina (AM)

As técnicas de Aprendizado de Máquina são métodos de indução que têm por objetivo a aquisição de conhecimento de forma automática como, por exemplo, através de um conjunto de dados fornecidos.

As técnicas de Aprendizado de Máquina podem ser divididas entre métodos de aprendizagem supervisionada (Árvores de decisão, K-Nearest Neighbour(KNN), Máquinas de Vetores de Suportes, Redes Neurais) e aprendizagem não supervisionada (*Clustering*).

Para o primeiro, o conjunto de dados separados entre treinamento e teste já possui grupos previamente classificados, possibilitando uma inferência para classificação de novos dados do grupo de teste. Já para aprendizagem não supervisionada, o grupo a que pertence cada dado não é fornecido e uma inferência deve ser feita apenas dos dados brutos.

Um recorrente empecilho para as técnicas de AM é a presença de *outliers*. Outliers são dados que diferem substancialmente dos demais dados do mesmo grupo, eles podem tanto ser exemplos de dados que de fato contrastam com outros dados do grupo, como também ser fruto de ruído presente no domínio. A correta forma de lidar com *outliers* é utilizar técnicas de aprendizagem mais flexíveis para permitir uma menor rigidez na classificação.

O termo “métodos de classificação” traduz-se em técnicas de Aprendizagem de Máquina que atribuem a conjuntos de dados diferentes classes, de acordo com um método de indução. A partir de um conjunto denominado de treinamento, o método de classificação induz uma lógica geral que possibilita a classificação de um grupo teste. Após a classificação de tal grupo, a eficiência do método de indução pode ser testada.

Para conjuntos de dados cujos rótulos não são discretos, ou seja, dados que podem ser rotulados por valores contínuos, utiliza-se o termo “métodos de regressão”, ao invés de “métodos de classificação”.

2.6.2 Teoria do Aprendizado Estatístico

A Teoria do Aprendizado Estatístico é a base do SVM. Ela é constituída por preceitos matemáticos que guiam a escolha de uma função de classificação de dados, a partir de um conjunto de dados de treinamento (VAPNIK, 1995).


Considere o caso de um conjunto de dados com 2 características, como apresentado na Figura 2. Os dados pertencem a dois conjuntos de dados distintos, representados aqui por triângulos e quadrados. Na intenção de criar uma regra de separação, pode-se utilizar uma fronteira de separação, que servirá para prever a qual classe novos dados pertencerão.

Na Figura 2a uma reta é utilizada para separar os dados das duas classes. Nota-se que alguns dados são separados erroneamente. Nesse caso diz-se que existe um sub-ajustamento (*underfitting*) ou seja, nessa classificação, muitos dados do próprio treinamento não são classificados corretamente, o que implica em pouco ajuste às amostras de treinamento.

Na Figura 2c todos os dados são classificados corretamente. Isso pode acarretar em uma classificação errônea de dados futuros, pois o classificador se super ajustou aos dados apresentados. Nesse caso, diz-se que houve um super ajustamento (*overfitting*) dos dados, pois o algoritmo tornou o classificador muito específico.

Em último caso, na situação b tem-se dois dados classificados nos grupos errados,

Figura 2 – Classe de dados com diferentes fronteiras de decisão



Fonte: (LORENA; CARVALHO, Abril 2003)


mas uma maior flexibilidade da fronteira de separação. Pode-se inferir que tais dados sejam *outliers*, como explicado anteriormente, e então, podem acarretar em erros de classificação se levados em conta no treinamento do classificador.

Como mostrado acima, a escolha de uma fronteira de separação é sensível e necessita de parâmetros e preceitos coerentes, o que é fornecido por meio da fundamentação teórica do TAE.

2.6.3 Máquinas de Vetores de Suporte Lineares com Margens Rígidas

Máquinas de Vetores de Suporte lineares descrevem problemas que são separáveis por um hiperplano. Um exemplo de separação, é mostrado na Figura 3.

Figura 3 – Conjunto de dados separados por um hiperplano, uma reta pode dividir os dois conjuntos de dados, e margens podem ser traçadas sem que nenhum dado esteja contido dentro dessas duas margens.



Fonte: (LORENA; CARVALHO, Abril 2003)

O hiperplano encontrado pelo algoritmo possui a maior margem possível, a qual é a distância entre a fronteira de decisão e os vetores de suporte do algoritmo. Os vetores

de suporte são os pontos mais próximos ao hiperplano, os quais definem a localização do hiperplano. Os vetores de suporte são tão importante, que se todos os outros dados do conjunto fossem retirados, deixando apenas os vetores suporte, a fronteira de decisão permaneceria a mesma.


No caso de Máquinas de Vetores de Suporte com Margens Rígidas, não se aceitam pontos entre as margens, como é o caso da [Figura 3](#). Tal abordagem não leva em conta a existência de possíveis *outliers*, ou ruído, que podem afetar a tomada de decisão do hiperplano de divisão.

2.6.4 Máquinas de Vetores de Suporte Lineares com Margens Suaves

Levando em conta pontos que podem ser afetados por ruídos como os denominados *outliers*, flexibilizar a margem, podendo existir exemplos de dados entre elas, se torna interessante.

Exemplos de dados entre as margens se encontram demonstrados na [Figura 4](#). Nessa imagem os dados são separados em duas classes, uma representada por circunferências e outro representado por triângulos.

Figura 4 – Conjunto de dados separados por um hiperplano suave. Cada figura geométrica, círculo ou triângulo, representa uma classe diferente de dados. Percebe-se que alguns dados caem entre as margens.



Fonte: ([PASSERINI, 2004](#))


Matematicamente, introduz-se um novo termo, responsável por indicar quão aceitável será ter dados entre as duas margens do classificador. Esse termo, caracterizado como

C , permite, quanto maior ele for, um maior número de dados entre as margens e quanto menor for, um menor número de termos entre as duas margens.

2.6.5 Máquinas de Vetores de Suporte Não-Lineares

Máquinas de Vetores de Suporte não lineares descrevem problemas que não são separáveis por um hiperplano. Em um conjunto de quatro pontos, por exemplo, pode haver uma configuração na qual não há um hiperplano de separação. Como exemplo, a [Figura 6](#) mostra a necessidade de utilização de duas fronteiras de decisão.

Figura 5 – Conjunto de dados não separáveis por um hiperplano.



Fonte: (LORENA; CARVALHO, Abril 2003)


Para contornar tal situação e fazer com que tais pontos sejam classificáveis, transferimos os dados para um espaço de maior dimensão (o chamado *feature space*), onde eles são linearmente separáveis. Para realizar tal operação, utilizamos a denominada função Kernel, a qual mapeia os dados para um espaço de dimensão maior.

O Kernel substitui a necessidade de definição explícita da transformação para um hiperespaço maior, chamada de $\phi(\cdot)$, que leva os pontos para o *feature space*. Por isso, nesse trabalho utilizaremos apenas o conceito de Kernel, a qual pode ser uma função qualquer, sem a explícita definição da função de transformação.


No exemplo da [Figura 7](#), os dados na figura da esquerda não são separáveis por um hiperplano, diz-se então que não são dados linearmente separáveis. O que pode ser feito, no entanto, é utilizar uma transformada ϕ que leve os dados com classificação “-” para fora do papel, tornando possível a classificação dos mesmos.

Na [Figura 7](#) da direita, um kernel gaussiano foi utilizado, possibilitando agora a separação dos dados por meio de uma fronteira não linear.

Figura 6 – Conjunto de dados não separáveis por um hiperplano.



Fonte: (LORENA; CARVALHO, Abril 2003)

Figura 7 – Conjunto de dados não separáveis por um hiperplano levados ao *feature space*.

Fonte: (CAMPBELL; YING, 2011)

3 Materiais e Métodos

3.1 Materiais

3.1.1 Detecção de Distorção Arquitetural Mamária

A detecção de Distorção Arquitetural Mamária segue uma série de passos simples. Depois de adquirida a imagem de mamografia, é realizada a detecção de áreas suspeitas (*Region of Interest* - ROI) com um descritor de padrões orientados, como o filtro de Gabor. Esses padrões orientados são regiões da mama que podem conter DAM ou não. Para eliminar os casos de falsos positivos (casos classificados como DAM mas que na verdade eram saudáveis) utiliza-se um descritor de textura. Esse descritor analisará cada uma das ROIs já selecionadas previamente e trará como saída um vetor de características, no caso do LMP, o qual é representado como o histograma da imagem após a utilização do descritor. Esse vetor de características é então utilizado como entrada em um classificador. Nessa etapa, espera-se eliminar os falsos positivos restando apenas os verdadeiros positivos (True Positive - TP), ou seja, regiões que efetivamente possuem a anomalia a ser detectada. Para efeito de simplicidade, foi assumido que as etapas iniciais que visam o levantamento das áreas suspeitas foram realizadas com sucesso.

3.1.2 Imagens de Mamografia Digitalizadas

Para efeito de trabalho, são necessárias imagens clínicas reais, que possuam laudo médico previamente realizado para a avaliação. Optou-se por utilizar o banco de imagens Digital Database for Screening Mammography (DDSM) (HEATH et al., 2000) muito consagrado na literatura e disponível publicamente na internet. Esse é um conjunto de um total de 200 imagens de mamografia analógica digitalizadas reais.

O banco de imagens DDSM (HEATH et al., 2000) se deu pela junção das seguintes insituições americanas: *University of South Florida, Sandia National Laboratories e Washington University School of Medicine* e apesar da perda de qualidade na digitalização de uma mamografia analógica, ainda é muito utilizada (JASIONOWSKA; PRZELASKOWSKI, 2010) (BANIK; RANGAYYAN; DESAUTELS, 2013) (OLIVEIRA et al., 2016) em diversos trabalhos. A disponibilização de tais materiais permite a manipulação de tais imagens como se desejar, dando espaço para ampla pesquisa.

No conjunto de todas as DDSM, as imagens são acompanhadas de laudo médico atestando a presença ou não de anomalia, assim como as coordenadas onde tal se encontra. Das 200 imagens, foram selecionadas 200 regiões aleatórias que não continham distorção


arquitetural feito o recorte e também foram retiradas as regiões de cada uma das imagens onde o laudo médico indicava que havia a DAM. Assim obtém-se um total de 400 imagens recortadas.

Esse processo acima citado, realizado manualmente, seria o procedimento realizado pelo filtro de gabor ou outra técnica de extração de regiões de interesse (automatizado), que não terão foco nesse trabalho.

Para melhor conseguir visualizar a Distorção Arquitetural realizou-se um pré-processamento das imagens, com um realce do contraste e uma subamostragem, permitindo a atenuação de ruídos e mantendo um padrão para o tamanho das ROIs. No final, todas as ROIs ficaram com dimensões 128x128 pixels.

A [Figura 8a](#) e a [Figura 8 b](#) são duas imagens retiradas do conjunto DDSM ([HEATH et al., 2000](#)) para título de exemplo. Elas figuram a mesma mama como um todo em visões diferentes e são imagens prévias ao processamento e extração de regiões suspeitas, as imagens também são citadas em ([OLIVEIRA et al., 2016](#)). Percebe-se de tal imagem a quantidade de estruturas que podem ser analisadas. No processo de detecção de DAM utilizam-se filtros de padrões orientados, como o filtro de gabor, para seleção das principais regiões suspeitas, previamente à utilização dos descritores de textura.

Figura 8 – Duas imagens retiradas do banco de imagens DDSM




Fonte: ([HEATH et al., 2000](#))

Após o pré-processamento mencionado, cada uma das imagens são substituídas por dois recortes, um que possui Distorção Arquitetural e outro com tecido saudável. Na [Figura 9](#), retirada de ([HEATH et al., 2000](#)) podemos observar as imagens após o pré-processamento. Na [Figura 9a](#) e na [Figura 9c](#) há presença de DAM enquanto na [Figura 9b](#)

e na [Figura 9d](#) há presença de tecido normal. Percebe-se que a DAM possui uma forma espiralada mais defina, sendo uma contração bem sutil no tecido e muitas vezes difícil de ser diagnosticada até pelos mais experientes radiologistas ([RAY et al., 2015](#))

Figura 9 – Quatro imagens 128x128 após o pré-processamento realizado no banco de imagens DDSM ([HEATH et al., 2000](#)). As figuras (a) e (c) possuem distorção arquitetural, enquanto que as imagens (b) e (d) possuem tecido saudável. Nota-se a presença de uma anomalia no tecido, diferente do tecido saudável, na presença de DAM.



Fonte: ([HEATH et al., 2000](#))

3.2 Métodos

3.2.1 Acurácia

Em todo esse estudo se utilizou como medida de aprovação dos métodos a acurácia. Ela é definida como segue na [Equação 3.1](#)

$$\text{Acurácia} = \frac{\text{DAM Verdadeiro Positivo} + \text{sem DAM Verdadeiro Negativo}}{\text{Número total de imagens}} \quad (3.1)$$

Essa medida é útil para definirmos a porcentagem de acerto de um método de descrição de textura combinado ao classificador. Se uma alta acurácia é apresentada no uso do método, então ele é bom para descrever DAM e imagens sem DAM, podendo tal medida ser usada como métrica de comparação entre métodos.

3.2.2 Extração das Características da Imagem

Seis características principais das imagens foram escolhidas para serem analisadas. Elas representam boa parte das características observáveis da imagem e por isso apresentam grande capacidade descritiva. Quatro delas são consagradas na literatura e muito utilizadas na descrição de diversos tipos de texturas, estão presentes nas denominadas matrizes de co-ocorrência de Haralick (VIEIRA et al., 2012) (CHIERICI et al., 2013) (FERRAZ et al., 2014) (FERRAZ; PEREIRA; GONZAGA, 2014b) (FERRAZ; PEREIRA; GONZAGA, 2014a) (NEGRI; GONZAGA, 2014) e as outras duas também importantes na descrição de texturas.

As características escolhidas consistem no Contraste, na Correlação, na Energia, na Homogeneidade, na Variância, e no Desvio Absoluto da Média (DAM), aplicados na ROI, após o pré-processamento e recorte.

3.2.3 Utilização de β fixo

Para método de comparação com as características extraídas da imagem, utilizou-se o LMP nas imagens com o mesmo β para todas, obtendo um gráfico de acurácia para todos.

Os β s testados situam-se na faixa de valores entre $(0 \ 1]$, onde a curvatura da função sigmóide varia entre 0 e 90 graus, e a variação entre os β s é de 0,005.

As imagens são divididas em dois grupos de 200 (desse grupo, 100 contém DAM e 100 são tecidos saudáveis), onde um grupo é utilizado para treinamento do classificador e o outro grupo é utilizado para teste da performance do classificador, com a acurácia avaliando seu desempenho. Para essas imagens, o grupo das imagens de teste e treinamento são fixos e cada valor de β é aplicado nas imagens do treinamento e nas imagens de teste, para serem utilizados no classificador. Assim, uma acurácia é obtida para esse β , repetindo-se esse procedimento para todos os valores de β no intervalo especificado.


3.2.4 Utilização de β dependente da imagem e separação das imagens por mediana

Para conseguir relacionar o melhor β com a característica da imagem, separou-se o conjunto de 400 imagens da DDSM (ROIs) em dois conjuntos, para cada característica

Para melhor exemplificar a Figura 10 digamos que estamos analisando o contraste das imagens. O valor de M seria a mediana do contraste de todas as imagens, incluindo DAM e sem DAM. Após obtenção de tal valor, separa-se as imagens entre o grupo com contraste maior do que M e contraste menor do que M , obtendo assim, dois grupos distintos. Essa análise foi repetida para as seis características da imagem analisadas, fornecendo 12 gráficos distintos.

Com a obtenção desses dois grupos, pôde-se testar os diferentes valores de β dentro do intervalo $(0, 1]$ e aplicar o SVM, como mostrado na Figura 11.

Figura 11 – Explicação da obtenção dos gráficos para escolha de β .



Fonte: autoria própria

Essa análise traz diferentes gráficos da performance de diferentes β para grupos com características distintas.

Após a obtenção desse gráfico, é possível realizar a escolha de β partindo das características da imagem. Basta olhar para o valor de β que obtém a maior acurácia, dado o gráfico correspondente a imagem (imagem com contraste $> M$ ou $< M$).

Para a escolha do β primeiramente, analisa-se uma característica individualmente, olhando para o valor máximo de um só gráfico obtido. Depois, analisa-se duas características distintas, fazendo uma análise mútua de dois gráficos de acurácia. Por fim, faz-se uma análise das 6 características, acumulando-se os respectivos gráficos e utilizando o valor de β que dá a maior acurácia.

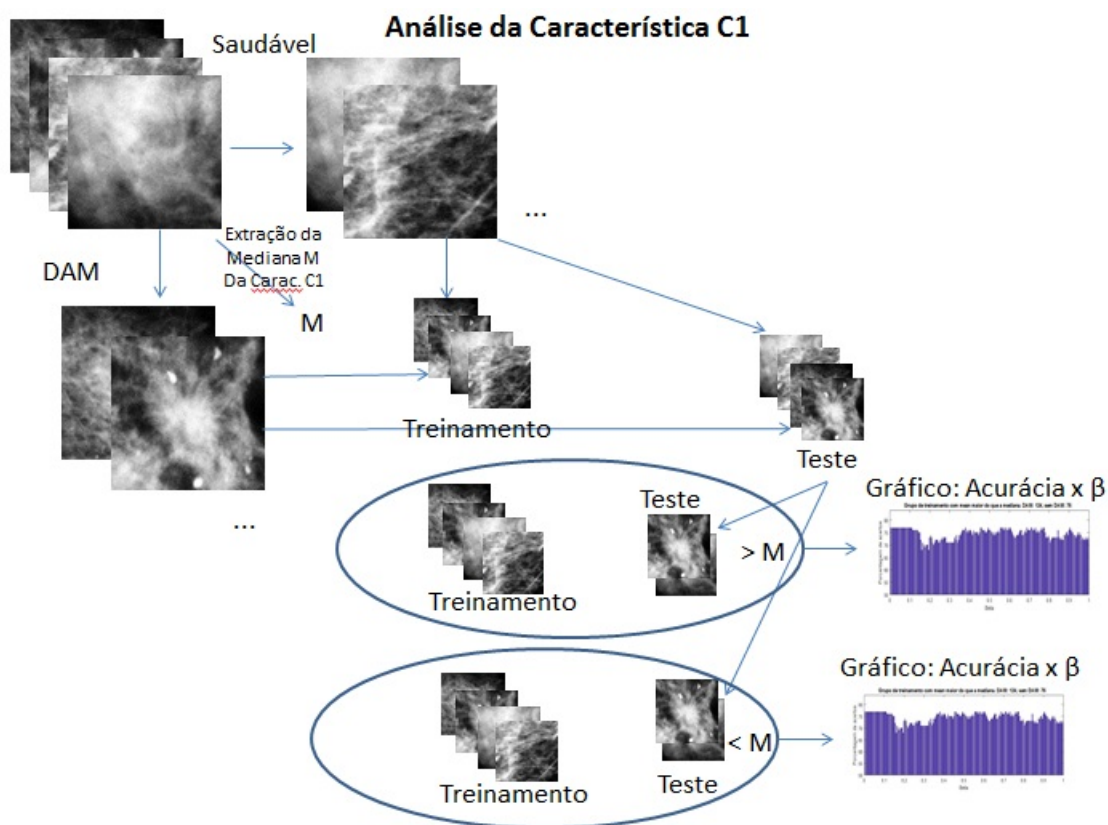
O valor de β é escolhido até para as imagens do treinamento, o que faz com que o grupo de treinamento seja previamente treinado, sem a necessidade de reprocessamento.

3.2.5 Classificação de uma imagem através da escolha de β segundo a imagem a ser classificada e utilização de tal valor β na descrição do conjunto de treinamento

A idéia de utilização da mediana será realizada de uma forma diferente, com apenas o grupo de teste sendo dividido. O grupo de treinamento permanecerá fixo, porém, para cada imagem a ser classificada, o grupo de treinamento será descrito com um β diferente, de acordo com a imagem sendo classificada.

A Figura 12 exemplifica melhor a separação realizada.

Figura 12 – Explicação da obtenção dos gráficos para escolha de β com grupo fixo de treinamento e β fixo dependente das características da imagem.



Fonte: autoria própria

Na Figura 12 vemos que apenas o grupo de teste foi dividido em dois, enquanto o grupo de treinamento permanece fixo.

Com tais gráficos, podemos dizer para quais valores de β , as imagens com característica superior ou inferior à mediana das características de todas as imagens melhor se descreve.

Nesse método, para uma nova imagem a ser classificada, analisa-se o gráfico obtido para imagens com características similares às dessa imagem. Primeiro a análise inicia-se com a utilização de somente uma característica, digamos contraste. Se o contraste de tal imagem for maior que a mediana, utiliza-se o gráfico obtido do método presente para imagens do teste com contraste maior do que a mediana. O valor de β é escolhido encontrando-se o valor máximo de acurácia desse gráfico.

Após a análise de uma só característica da imagem, faz-se a combinação de duas características. Os gráficos são somados ponto à ponto (para cada valor de β o valor de acurácia dos dois gráficos é somado), o β que obtém o valor máximo de acurácia da soma dos dois gráficos é utilizado. Por último, soma-se os gráficos ponto a ponto das seis características da imagem e utiliza-se o valor de β que apresenta o maior valor de acurácia.

3.2.6 Classificador

O classificador escolhido para analisar o vetor de características foram as Máquinas de Vetores de Suporte, porque era necessário utilizar um método de classificação supervisionado e a escolha do *kernel* do SVM permite uma maleabilidade dependendo do problema que estamos tratando. Para transferirmos os dados para um espaço de maior dimensão (o chamado *feature space*), onde eles são linearmente separáveis, utilizamos a função Kernel, a qual mapeia os dados para um espaço de dimensão maior. O Kernel substitui a necessidade de definição explícita da transformação para um hiperespaço maior, chamada de $\phi(\cdot)$, que leva os pontos para o *feature space*. Por isso, nesse trabalho utilizaremos apenas o conceito de Kernel, sem a explícita definição da função de transformação. A escolha do Kernel foi feita com base na melhor performance para classificar as imagens com β fixo. A média de acurácia de todos os β s obteve maior porcentagem quando o kernel é Gaussiano, com sigma de 7,75 e constante C de margens suave de 0,002.

3.2.7 MATLAB

No MATLAB, duas funções principais permitem a utilização do algoritmo do SVM, são elas “*svmtrain*” e “*svmclassify*”. O primeiro é utilizado para o conjunto de dados de treinamento, onde o kernel deve ser especificado assim como os seus parâmetros. A segunda função, “*svmclassify*”, apenas recebe a saída do algoritmo do “*svmtrain*” o qual é uma estrutura do SVM treinado, e um conjunto novo de dados a serem classificados. A sua saída consiste no grupo a que pertence cada dado do conjunto de teste.

4 Resultados e Discussões

4.1 Utilização de β fixo

O método mais intuitivo de classificação das imagens, com e sem DAM, é utilizar o descritor LMP com um β fixo, ou seja, em cada classificação, um mesmo β é usado no grupo de treinamento e também no grupo teste. Utilizando os β s no intervalo de 0 e 1, com uma variação de 0,005. Separou-se um grupo de treinamento de 200 imagens e um grupo de teste de 200 imagens diferentes, ambos grupos fixos. O histograma das imagens após a utilização do descritor LMP foi utilizado como entrada no classificador SVM com Kernel Gaussiano, Sigma 7,75 e $C = 0,002$.

O gráfico da acurácia em função de cada β , se encontra na [Figura 13](#). Nele observa-se que o valor máximo de acurácia é 81,5% para quatro valores de β , dentre eles o valor de 0,375.

Ao utilizar o método LBP, como comparação, obtém-se uma acurácia de 67%. Nota-se que o método LMP possui uma acurácia melhor do que o LBP para quaisquer valor de β utilizados.

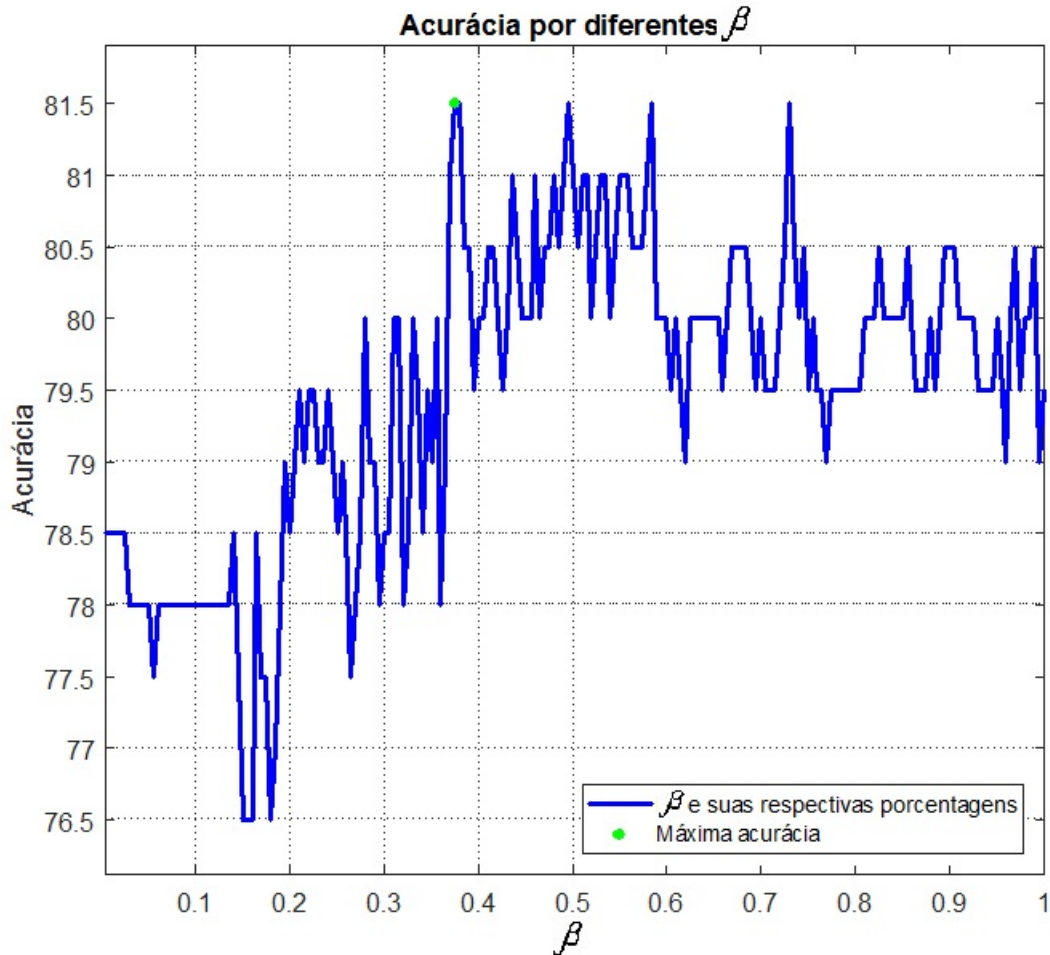
Para melhor entender como as características da imagem se relacionam com a presença ou não de DAM, os seguintes gráficos podem ser úteis. Da [Figura 14](#) até a [Figura 18](#) vê-se que uma faixa de características mantém a maioria das imagens com e sem DAM separadas e em apenas uma pequena faixa de valores, têm-se imagens com e sem DAM misturadas.

Na [Figura 14](#) observa-se que para valores de contraste menores do que 0,12 e para valores de correlação maiores do que 0,99, a maioria das imagens possuem DAM, enquanto as imagens sem DAM estão na mesma linha porém distribuídos mais para o eixo das abcissas. Observa-se também que o contraste e a correlação apresentam quase que uma relação linear entre os dois, podendo sugerir que trabalhar com o contraste a correlação seja uma redundância.

No gráfico [Figura 15](#) vemos que os dados estão distribuídos de forma parecida com a função $\frac{1}{x}$ e que alguns pontos de *outliers* são observáveis fora dessa região de comportamento. Para valores menores do que 0,12 de contraste, a maioria dos pontos possuem DAM, assim como para valores de energia maiores do que 0,1 a maioria das imagens também possuem DAM. Uma análise parecida para a região das imagens sem DAM poderia ser realizada, com a sugestão de outros limites de valores.

No gráfico [Figura 16](#) vê-se uma relação quase que perfeitamente linear entre o

Figura 13 – Gráfico mostrando a acurácia na classificação das imagens com e sem DAM, utilizando o descritor de textura LMP para diferentes valores de β e o classificador SVM.




Fonte: autoria própria

contraste e a homogeneidade das imagens de mamografia analisadas. Para valores de homogeneidade abaixo de 0,85 a maioria dos pontos não possuem Distorção Arquitetural.

No gráfico [Figura 17](#) vê-se uma relação menos linear entre as duas variáveis, porém, nota-se que eles estão bem definidos em uma região específica do plano. Da mesma forma que os gráficos anteriores, há uma região de valores de energia e correlação nos quais as imagens com DAM e sem DAM ambas estão localizadas, o que explica a dificuldade de classificação entre esses dois tipos de imagens.


No gráfico [Figura 18](#) uma faixa de valores apresenta imagens com e também imagens sem DAM, nota-se que valores acima e 0,98 de correlação estão quase que diretamente ligados com a presença de DAM.

Figura 14 – Gráfico que relaciona o contraste, a correlação e a presença de Distorção Arquitetural nas imagens mamográficas analisadas.




Fonte: autoria própria

Figura 15 – Gráfico que relaciona o contraste, a energia e a presença de Distorção Arquitetural nas imagens mamográficas analisadas.




Fonte: autoria própria

Figura 16 – Gráfico que relaciona o contraste, a homogeneidade e a presença de Distorção Arquitetural nas imagens mamográficas analisadas.




Fonte: autoria própria

Figura 17 – Gráfico que relaciona a energia, a correlação e a presença de Distorção Arquitetural nas imagens mamográficas analisadas.



Fonte: autoria própria

Figura 18 – Gráfico que relaciona a homogeneidade, a correlação e a presença de Distorção Arquitetural nas imagens mamográficas analisadas.



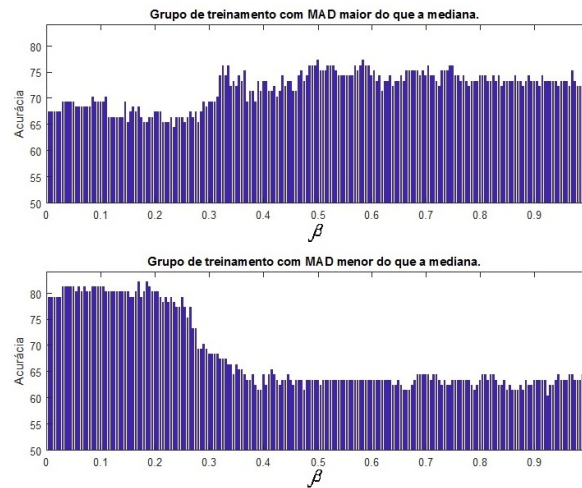
Fonte: autoria própria

4.2 Utilização de β dependente da imagem e separação das imagens por mediana

Uma segunda forma de classificação seria utilizando diferentes β s para cada imagem, partindo do pressuposto que existem β ótimos para descrever cada imagem. Uma forma intuitiva de encontrar o melhor β para cada imagem, seria partindo da análise das suas características. Aqui se dividiu o grupo de treinamento e o grupo de testes entre aqueles maiores do que a mediana e menores, obtendo dois gráficos para cada característica.


A acurácia por grupo se encontra nas imagens a seguir, da [Figura 19](#) até a [Figura 24](#).

Figura 19 – Acurácia por diferentes valores de β s com grupos de treinamento e de testes divididos entre imagens com Desvio Médio Absoluto (MAD) maior do que a mediana de todas as imagens, a), e menor do que a mediana de todas as imagens b). O gráfico de cima, para MAD maior do que a mediana, possui um valor de acurácia maior para β s maiores do que 0,5, o que pode dizer que utilizar valores maiores do que 0,5 para classificar imagens com MAD menor do que a mediana aqui considerada é vantajoso.



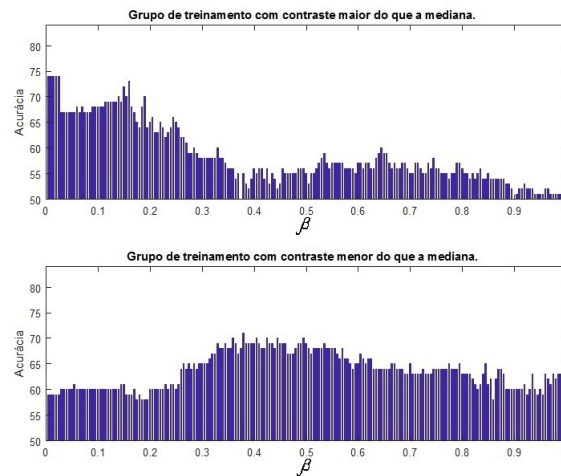
Fonte: autoria própria

Figura 20 – Acurácia por diferentes valores de β s com grupos de treinamento e de testes divididos entre imagens com variância maior do que a mediana de todas as imagens, a), e menor do que a mediana de todas as imagens b). Esse gráfico possui uma região definida de β para os quais a acurácia apresenta bom desempenho, valores menores do que 0,3 apresentam alto desempenho. Se correlacionado com o gráfico de MAD maior do que a mediana, vê-se que os dois não podem ser satisfeitos ao mesmo tempo.



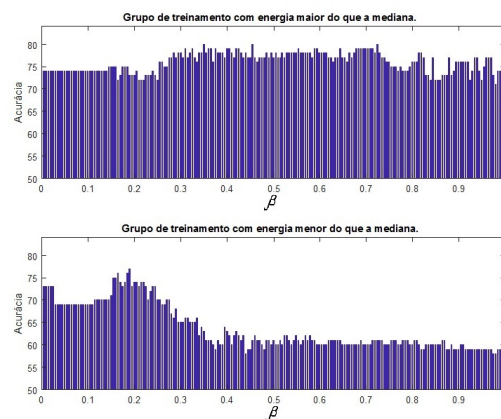
Fonte: autoria própria

Figura 21 – Acurácia por diferentes valores de β s com grupos de treinamento e de testes divididos entre imagens com contraste maior do que a mediana de todas as imagens, a), e menor do que a mediana de todas as imagens b). No grupo de treinamento com contraste maior do que a mediana não se obteve uma acurácia maior do que 65%. Isso indica que imagens com contraste maior do que a mediana não possuem regiões bem definidas, ou separadas, de imagens com e sem DAM.




Fonte: autoria própria

Figura 22 – Acurácia por diferentes valores de β s com grupos de treinamento e de testes divididos entre imagens com Energia maior do que a mediana de todas as imagens, a), e menor do que a mediana de todas as imagens b) Para as imagens com energia maior do que a mediana, a detecção de DAM é boa para qualquer valor de β , o que indica uma alta distinção de energia entre as imagens com e sem DAM com energia maior que a mediana. Enquanto a alta energia ajuda na classificação, a baixa energia parece atrapalhar, com acurção em torno de 70%



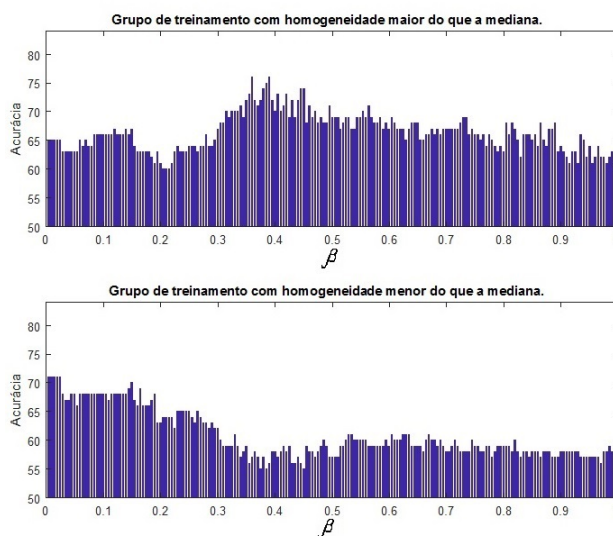
Fonte: autoria própria

Figura 23 – Acurácia por diferentes valores de β s com grupos de treinamento e de testes divididos entre imagens com Correlação maior do que a mediana de todas as imagens, a), e menor do que a mediana de todas as imagens b). O gráfico da correlação maior que a mediana possui alguns vales, sem um comportamento bem definido, a sua acurácia gira em torno de 70%. Enquanto imagens com baixa correlação apresentam acurácias baixíssimas, em torno de 50%ll



Fonte: autoria própria

Figura 24 – Acurácia por diferentes valores de β s com grupos de treinamento e de testes divididos entre imagens com homogeneidade maior do que a mediana de todas as imagens, a), e menor do que a mediana de todas as imagens b) Para os gráficos de homogeneidade, o comportamento da acurácia para os diferentes β s tem acurácia muito baixa, sem regiões bem definidas para a escolha do melhor beta.



Fonte: autoria própria

Tabela 1 – Acurácia obtida quando se estava analisando cada característica da imagem individualmente.

Método	Acerto (%)
Contraste	77,5
Correlação	80
Energia	78,5
Homogeneidade	77,5
Variância	82
Desvio absoluto da média	77

Tabela 2 – Acurácia obtida quando se estava analisando duas características da imagem em conjunto.

Método	Acerto (%)
Desvio absoluto da média e variância	77,5
Variância e Contraste	80
Contraste e correlação	78,5
Correlação e energia	77,5

Após traçar o gráfico para cada grupo, percebe-se que algumas possuem um comportamento mais definido. Por exemplo, analisando o gráfico do Desvio Absoluto da Média (MAD), utilizar um β abaixo de 0,25 para imagens com MAD menor do que a mediana parece trazer maior acurácia.

Com esses gráficos como parâmetros, podemos escolher o melhor β para cada imagem analisando alguma de suas características. No caso, se o MAD de uma imagem for menor do que a mediana dos MADs o β que provavelmente trará a maior quantidade de acertos deveria ser um β menor do que 0,25 (basta pegar o valor máximo do gráfico de acurácia). Com as outras características, podemos combinar essas diferentes condições e testar diferentes possibilidades (utilizar o valor máximo).

Utilizando tais conceitos de intervalos de β s melhores, pode-se realizar o teste com diferentes condições. Os próximos testes foram realizados utilizando-se apenas uma característica da imagem. Mostra-se na [Tabela 1](#)

Para se ter uma maior confiabilidade nas condições, pode-se utilizar não só uma característica da imagem, como mais de uma. Aqui também foram utilizadas duas características da imagem, observando o comportamento dos gráficos obtidos acima, para determinação do melhor β (soma-se os dois gráficos, reajustados para estarem no intervalo de $(0 \ 1]$ e pega-se o valor máximo). Os resultados obtidos se encontram na [Tabela 2](#).

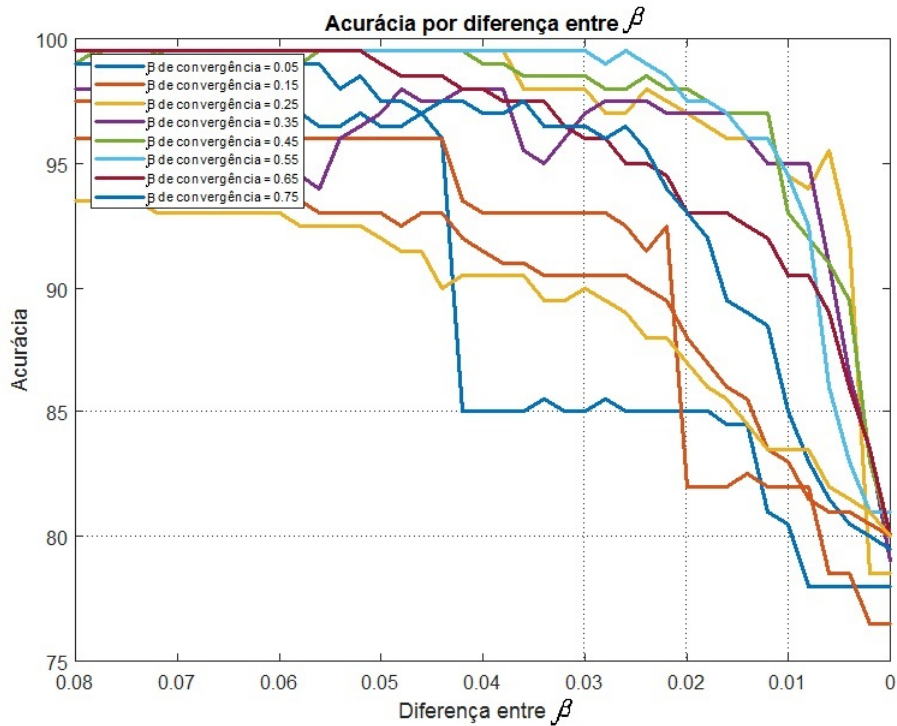
Para incorporar todos as características como condições importantes na decisão do β , os gráficos de acurácia para todas as condições de características das imagens foram acumulados. Neste caso, para uma imagem com correlação maior do que a mediana e homogeneidade maior do que a mediana, por exemplo, somaram-se os dois gráficos respectivos, ou seja, o gráfico *a* da [Figura 23](#) e o gráfico *a* da [Figura 24](#). O mesmo procedimento foi realizado com as outras características da imagem, obtendo-se, ao final, um gráfico do acúmulo de tais β s. No final, o β escolhido seria o β com porcentagem máxima, dos gráficos somados ponto a ponto. De modo a obter uma consideração equiparável de cada características, os gráficos de cada características foram escalados para estarem dentro da faixa de valores de 0 a 1.

O valor da porcentagem obtida com esse método foi de 81,5%.

4.3 Análise das consequências da utilização de diferentes β s para cada imagem

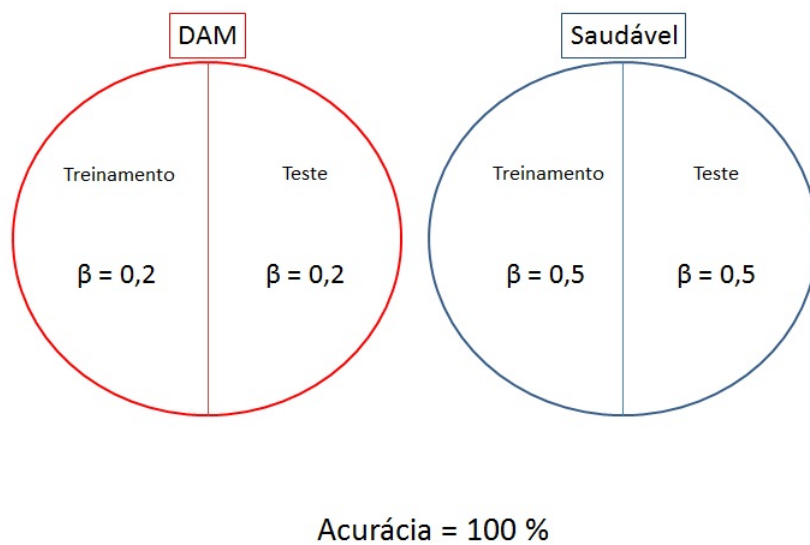
Os resultados acima pedem uma análise mais profunda da confiabilidade de utilização de diferentes β s para separação das características das imagens. Para se obter tal análise, dois grupos foram separados, das 400 imagens. Para o grupo com DAM, utilizou-se um β , e para o grupo sem DAM, utilizou-se outro. Assim, separamos também um grupo para ser utilizado como treinamento e outro como de teste. A diferença entre os dois β s utilizados foi diminuída, até que fosse utilizado o mesmo β para os dois grupos, para analisar o que ocorreria com a acurácia. A [Figura 25](#) mostra que utilizando-se β s distintos para as imagens com DAM e sem DAM, a porcentagem de acerto é próxima de 100%. Quanto mais aproximamos um β do outro, mais essa porcentagem cai.

Figura 25 – Acurácia em função da diferença entre β s, convergindo para diferentes β s.



Fonte: autoria própria

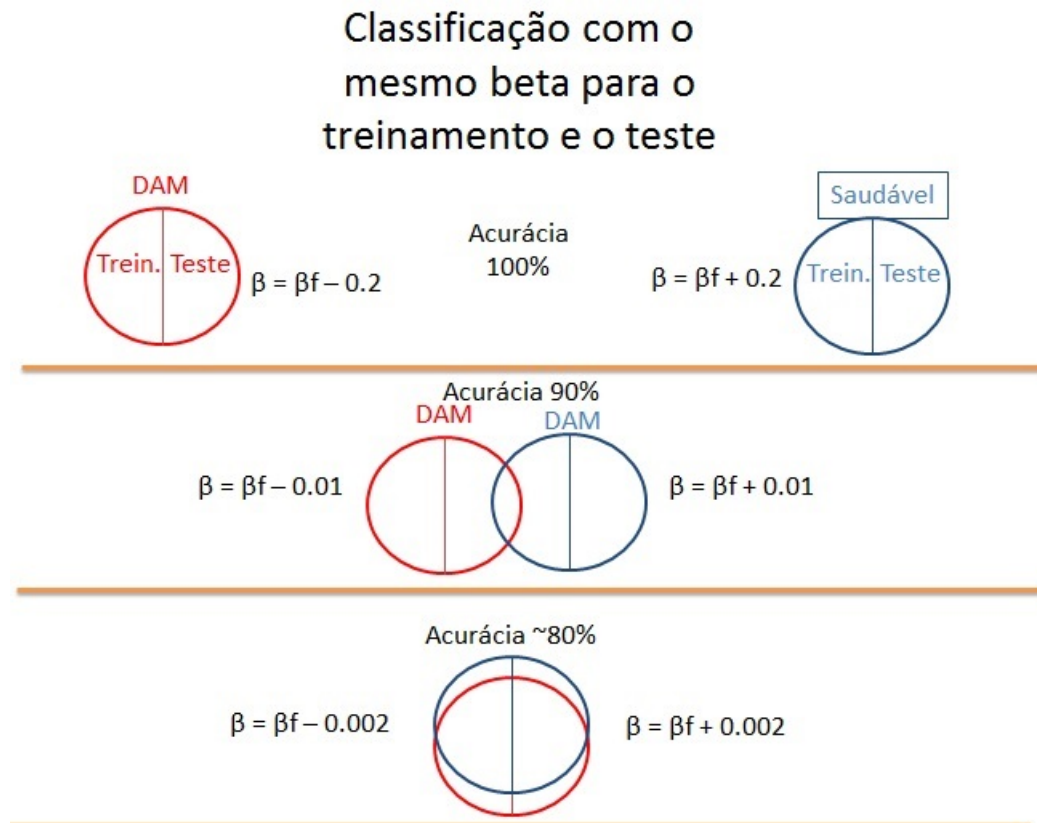
Figura 26 – Imagem que exemplifica a escolha de um β para o grupo de DAM para o grupo de treinamento e de teste e um diferente β para as imagens sem DAM grupo de treinamento e de teste. A acurácia obtida assim é a máxima



Fonte: autoria própria

O resultado desse experimento, encontra-se ilustrado na [Figura 26](#), que indica a acurácia de 100% quando os grupos com DAM e sem DAM são descritos com o uso de β distintos. Na [Figura 27](#) encontra-se o caso de β que se aproximam para um mesmo valor.

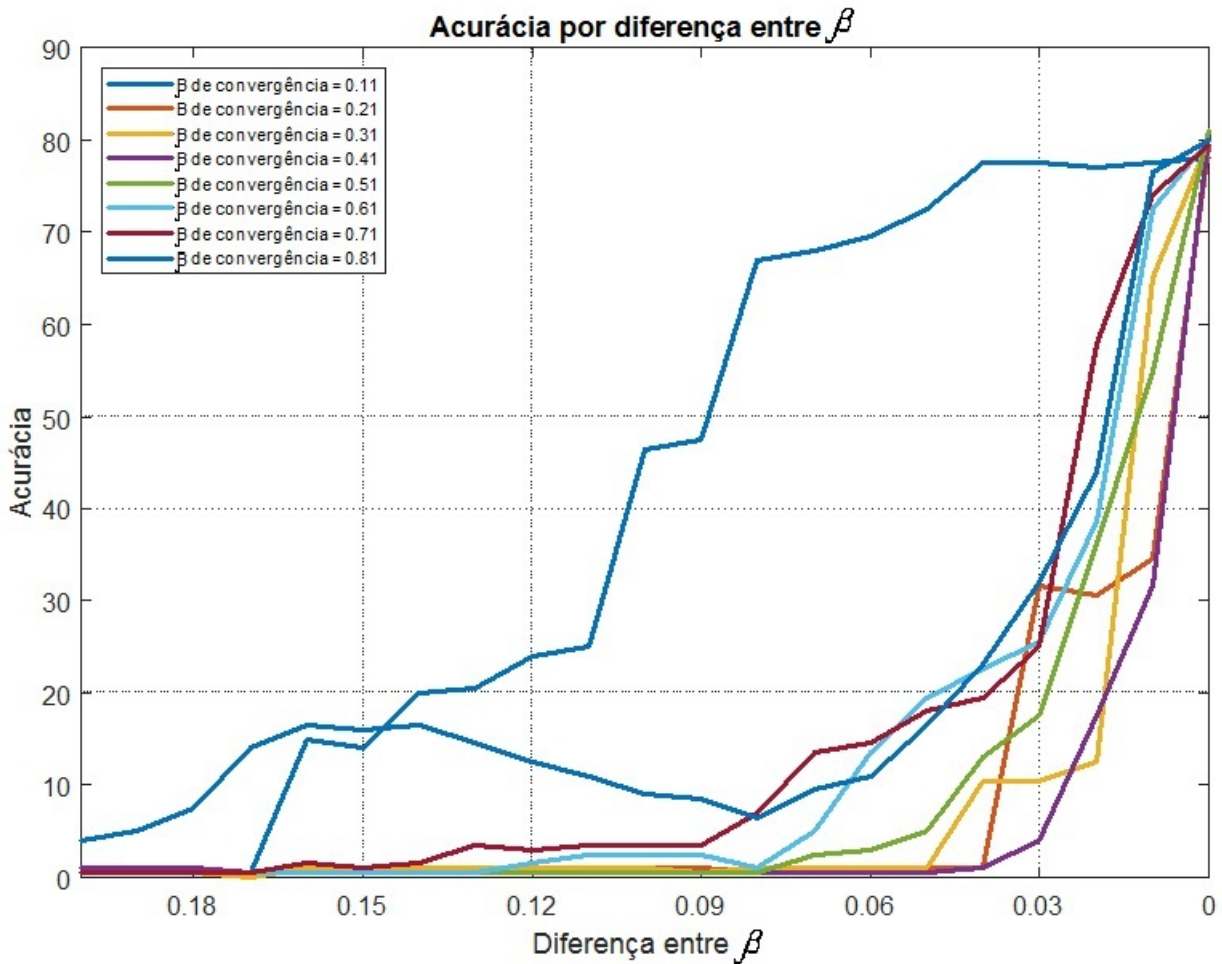
Figura 27 – Imagem que exemplifica a escolha de dois β s, um para DAM teste e treino e outro para sem DAM teste e treino. Os dois β s utilizados convergem até se tornarem o mesmo valor, β_f , provando a intersecção dos dados.



Fonte: autoria própria

Para uma análise mais criteriosa, realizou-se um outro teste. Para o grupo de treinamento, um β_x foi utilizado para as amostras com DAM e um β_y para as imagens sem DAM. No grupo teste, os valores de β foram invertidos, x foi utilizado para as amostras sem DAM e y para as amostras com DAM. O mesmo procedimento foi realizado, até que os β s ficassem muito próximos, convergindo para um mesmo valor. A [Figura 28](#) mostra o resultado obtido com esse teste.

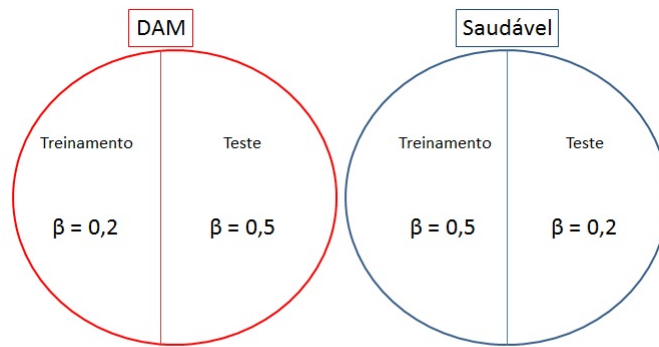
Figura 28 – Acurácia em função da diferença entre β s, convergindo para um β . Os betas opostos foram utilizados no grupo de testes



Fonte: autoria própria

Os resultados obtidos nessas figuras são ilustrados na [Figura 29](#), onde observa-se que a utilização de valores de β diferente para o grupo de treinamento e para o grupo de teste acarreta em 0% de acerto. O caso em que os valores de β vão se aproximando são mostrados na [Figura 30](#). Nesse ponto, vê-se como o encontro dos β s provê também um encontro dos vetores de características no espaço, os quais podem agora serem classificados corretamente.

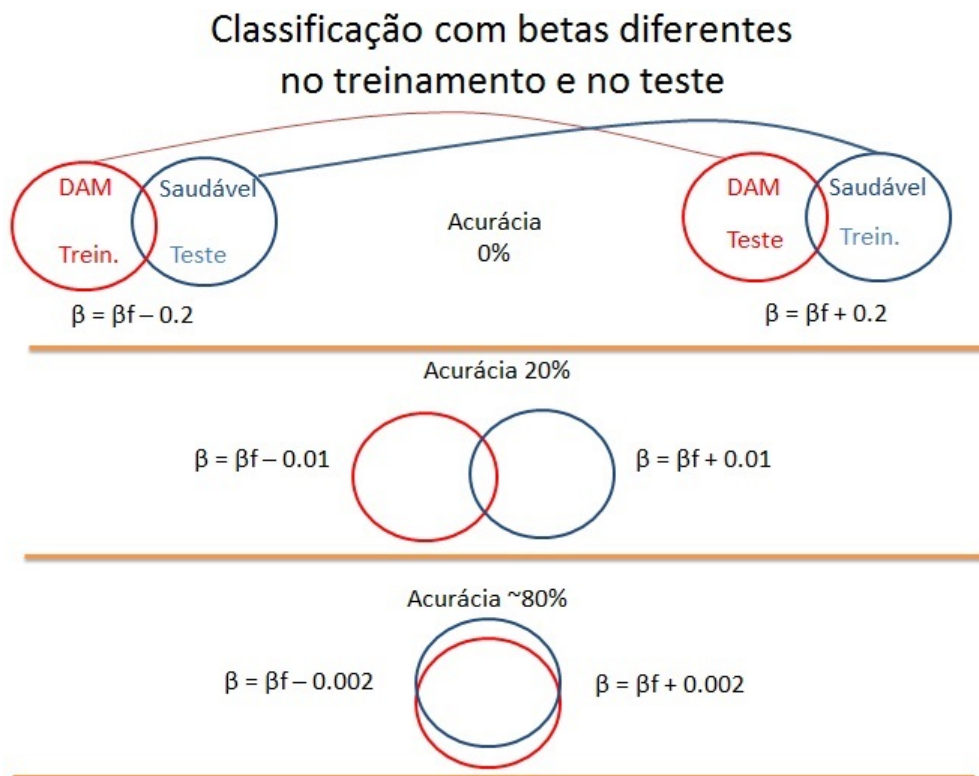
Figura 29 – Imagem que exemplifica a escolha de diferentes β s para o grupo de treinamento de DAM e de teste de DAM e os β s inversos para sem DAM teste e treinamento.



Acurácia = 0 %

Fonte: autoria própria

Figura 30 – Imagem que exemplifica a escolha de diferentes β s para o grupo de treinamento de DAM e de teste de DAM e os β s inversos para sem DAM teste e treinamento. Aqui é mostrado como a convergência para um mesmo β influe na intersecção desses grupos, ajudando na acurácia.



Fonte: autoria própria

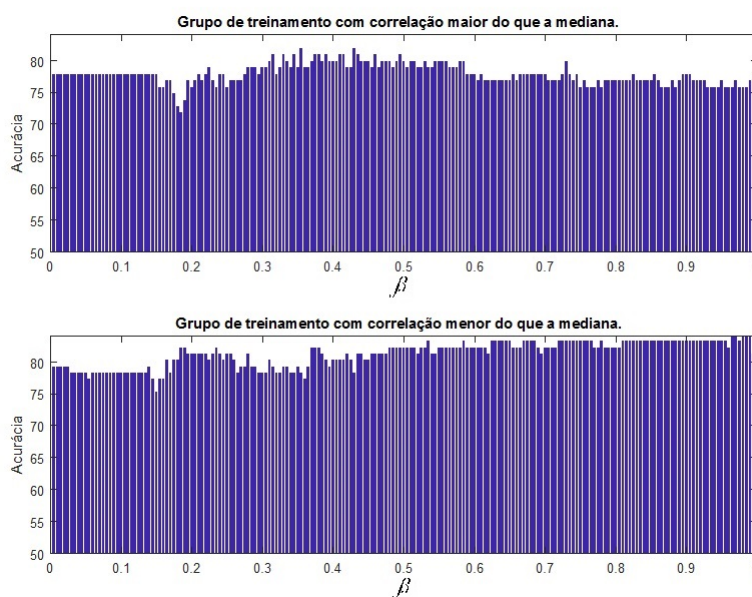
4.3.1 Utilização de β fixo para o grupo de treinamento e para uma imagem

Tendo em vista os gráficos obtidos acima, uma possível nova técnica seria utilizar para o grupo de treinamento o mesmo β que será utilizado para classificar uma nova imagem. Assim, cada vez que uma nova imagem for classificada, o grupo de treinamento é treinado com esse β e a imagem é então classificada. Isso faz com que a individualidade de cada imagem seja levada em conta, sem utilizar diferentes β s na classificação, que mostra não ser tão eficiente como mostrado na [Figura 25](#) e na [Figura 28](#).

Realizando um procedimento similar ao realizado com β s distintos para cada imagem, as imagens com característica maior do que a mediana serão separadas em um grupo, sendo então classificadas com o mesmo β e mesmo grupo de treinamento, diferentemente do procedimento anterior.

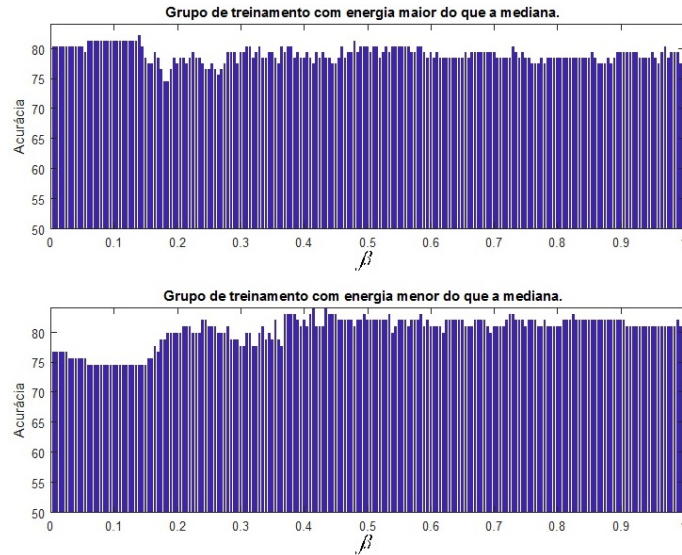
Os gráficos de acerto obtidos com tal procedimento mostram-se desde a [Figura 31](#) até a [Figura 36](#). As outras características que foram analisadas anteriormente das imagens também foram levadas em conta, porém o gráfico delas não mostrou ter um padrão bem definido para ser utilizado como método de classificação do β .

Figura 31 – Acurácia obtida em função dos diferentes valores de β quando o grupo teste é dividido entre aqueles com correlação maior do que a mediana, gráfico de cima, e menor do que a mediana, gráfico de baixo. Esses dois gráficos mostram a alta taxa de acurácia para qualquer um os valores de mediana, o que indica robustez desse método de classificação.



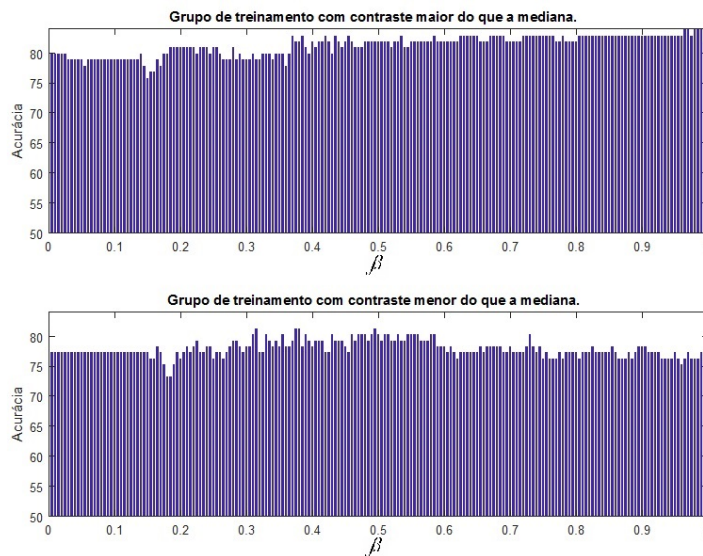
Fonte: autoria própria

Figura 32 – Acurácia obtida em função dos diferentes valores de β quando o grupo teste é dividido entre aqueles com energia maior do que a mediana, gráfico de cima, e menor do que a mediana, gráfico de baixo. O grupo com energia menor que a mediana apenas possui uma queda na acurácia para β s menores que 0,2, mas uma boa taxa para os outros valores de β .




Fonte: autoria própria

Figura 33 – Acurácia obtida em função dos diferentes valores de β quando o grupo teste é dividido entre aqueles com contraste maior do que a mediana, gráfico de cima, e menor do que a mediana, gráfico de baixo. A diferença em contrastes não altera a acurácia total do método, fazendo com que qualquer escolha de β seja vantajosa.



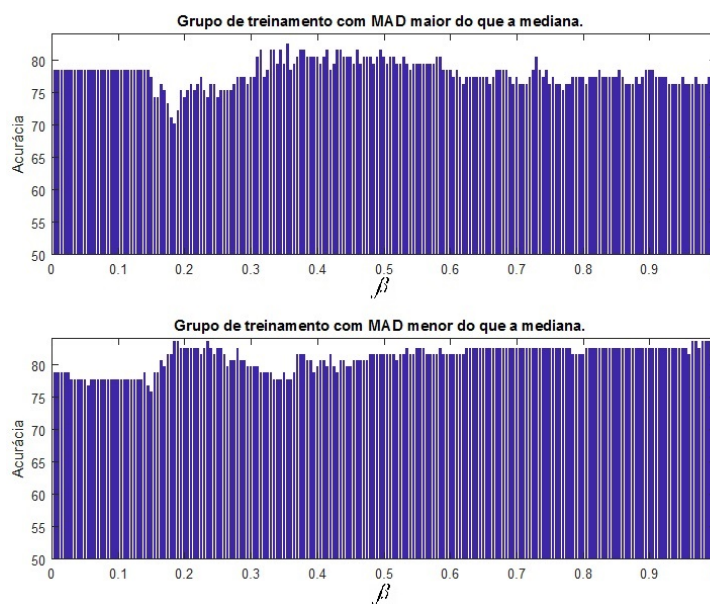
Fonte: autoria própria

Figura 34 – Acurácia obtida em função dos diferentes valores de β quando o grupo teste é dividido entre aqueles com homogeneidade maior do que a mediana, gráfico de cima, e menor do que a mediana, gráfico de baixo.




Fonte: autoria própria

Figura 35 – Acurácia obtida em função dos diferentes valores de β quando o grupo teste é dividido entre aqueles com desvio absoluto em relação à media maior do que a mediana, gráfico de cima, e menor do que a mediana, gráfico de baixo. A diferença na MAD não altera a acurácia total do método, fazendo com que alquer escolha de β seja vantajosa.



Fonte: autoria própria

Figura 36 – Acurácia obtida em função dos diferentes valores de β quando o grupo teste é dividido entre aqueles com variância maior do que a mediana, gráfico de cima, e menor do que a mediana, gráfico de baixo. No caso desses dois gráficos, também ocorre alta acurácia, o que não faz do β um fator decisivo para bom desempenho desse classificador.



Fonte: autoria própria

Os resultados obtidos, se encontram na [Tabela 3](#), tendo em vista que apenas uma característica foi levada em conta na hora de se escolher o β e o resultado do gráfico acumulado também foi realizado. Na escolha do melhor β em função da característica, os gráficos da [Figura 31](#) até a [Figura 36](#) foram levados em conta, onde a característica da imagem ser maior ou menor que a mediana da mesma característica de todas as imagens foi levada em conta.

Para método de comparação, utilizamos o SVM tendo como entrada alguns parâmetros da imagem, como o contraste, a correlação, a energia, a homogeneidade e uma combinação desses quatro parâmetros. Também utilizou-se o descritor LBP, obtendo-se a [Tabela 4](#)

Juntando todos os melhores métodos obtidos em uma só tabela, para método de

Tabela 3 – Acurácia obtida na análise de uma característica da imagem para escolha do valor de β . Grupo de treinamento treinado com o mesmo valor de β , para cada imagem a ser classificada.

Característica de escolha do β	Acurácia (%)
Gráficos somados ponto a ponto	82
Desvio absoluto da média	81
Variância	81
Contraste	80,5
Correlação	80,5
Energia	80,5
Homogeneidade	78,5

Tabela 4 – Métodos utilizados como entrada direta no SVM. Utilização de β fixo, para o LMP.

Método	Acerto (%)
Contraste	57
Correlação	54,5
Energia	74,5
Homogeneidade	63,5
Contraste, Correlação, Energia e Homogeneidade	64
LBP	67
LMP ($\beta = 0.375$)	81,5

Tabela 5 – Melhores métodos utilizados para escolha do β versus acurácia.

Método	Acerto (%)
Diferentes β s, escolhidos pela variância	82
Diferentes β s, escolhidos pela variância e contraste	80
Grupo de treinamento com mesmo β da imagem, gráficos somados ponto a ponto	82
β fixo = 0,375 no SVM	81,5

comparação, obtemos a [Tabela 5](#).

As relações entre as características da imagem e a presença de DAM justificam a alta acurácia de métodos que usam de características de descrição da imagem simples, como o contraste, a homogeneidade e a energia. Pois, para uma faixa de contraste específica, por exemplo, as chances de existirem imagens com distorção arquitetural são muito maiores.

Os métodos para classificação que separaram as imagens entre aquelas abaixo da característica da mediana não são muito eficientes, pois utilizam diferentes valores de β para cada imagem. Mesmo assim, a taxa de detecção de DAM não é irrisória. Isso se deve ao fato dos gráficos de contraste x homogeneidade, por exemplo, apresentarem regiões do plano onde é mais comum a presença de distorção, o que torna possível uma certa separação entre imagens com características acima de um valor, ou abaixo.

Vemos que quando os β s para DAM e sem DAM são distintos eles levam as imagens para regiões distintas, que facilitam a classificação da DAM. Apenas quando a diferença entre os dois β é mínima é que começa a se notar a intersecção dos dois grupos separados. A diferença entre os valores de β que permitem que os vetores de características se interceptem é cerca de 0,01, um valor muito baixo se comparado com cada escolha de beta. Isso implica na escolha prévia de um beta para a distorção Arquitetural e outro para a imagem sem Distorção Arquitetural, o que se torna impossível.

Da [Tabela 5](#) vê-se que os métodos utilizando diferentes β s obtém uma performance satisfatória, porém não são confiáveis, devido à diferentes β s levarem a regiões distintas do plano.

O segundo método testado, o qual utiliza o mesmo grupo de treinamento que é treinado com diferentes β s dependendo da imagem, provou ter uma melhor performance. Porém pode-se estimar um alto custo computacional para esse método, para descrever as imagens do treinamento com um β diferente, a cada nova imagem a ser classificada.

5 Conclusão

Esse trabalho teve como objetivo analisar a relação entre a parametrização do descritor de texturas *Local Mapped Pattern* e as características da imagem, na tentativa de encontrar o melhor parâmetro β para cada imagem.

Nesse trabalho, encontrou-se acurácias para descrição de texturas com o *Local Mapped Pattern* com um β fixo superior a outros métodos comuns na literatura como as matrizes de co-ocorrência de Haralick e ao descritor de textura *Local Binary Pattern*.

A separação de grupos de imagens de acordo com as suas características não levou à obtenção de uma acurácia superior, exceto no caso em que o grupo de treinamento foi mantido fixo, mas treinado com um β diferente, dependendo da imagem a ser classificada. Esse método demanda um custo computacional maior e a acurácia apresenta somente 0,5% de vantagem na detecção, quando comparada ao uso do β fixo.

Levando em conta que a utilização de diferentes β s para o grupo de treinamento não é um método confiável e utilizar β para o grupo de treinamento dependendo da característica da imagem acarreta em um custo computacional maior, a melhor escolha para as imagens de mamografia é a utilização de um β fixo, no caso, de 0,375 ao se utilizar um classificador SVM com as mesmas características aqui utilizadas.

Resultados diferentes poderiam ser obtidos se diferentes classes de imagens fossem utilizadas. As imagens utilizadas neste trabalho apresentam-se como um nicho específico, sendo todas retiradas de exames mamográficos, de tecidos mamários com características levemente distintas. Todos os resultados obtidos aplicam-se somente a esse grupo específico de imagens.

6 Contribuição e Trabalhos Futuros

Durante a realização deste trabalho, houve a contribuição na publicação de um artigo para apresentação na SPIE Medical Imaging 2017 (OLIVEIRA et al., 2017), onde o descritor *Local Mapped Pattern* foi também utilizado para descrição de imagens mamográficas. Espera-se com essas publicações, poder contribuir no desenvolvimento da detecção prévia de câncer de mama, antecipando milhares de diagnósticos tardios, que sem a ajuda dos sistemas computacionais, não seriam detectados.

Como possíveis estudos futuros cita-se a análise da melhor escolha do β fixo para um conjunto de imagens a partir das suas características, como contraste e correlação. Além disso, são possíveis aplicações de outras funções de entrada ao LMP, que não a função sigmóide e futuro uso de tal aplicação na caracterização da Distorsão Arquitetural Mamária.

Referências

- AHONEN, T.; HADID, A.; PIETIKAINEN, M. Face description with local binary patterns: Application to face recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 39(3), p. 2037–2041, 2006. Citado na página 23.
- BAKER, J. A. et al. Computer-aided detection (cad) in screening mammography: Sensitivity of commercial cad systems for detecting architectural distortion. *American Journal of Roentgenology*, v. 181, p. 1083–1088, 2003. Citado 2 vezes nas páginas 18 e 22.
- BANIK, S.; RANGAYYAN, R.; DESAUTELS, J. E. L. Detection of architectural distortion in prior mammograms. *IEEE Transactions on Medical Imaging*, v. 30(2), p. 279–294, 2013. Citado 2 vezes nas páginas 18 e 32.
- CAMPBELL, C.; YING, Y. *Learning with Support Vector Machines*. 10. ed. [S.l.]: Morgan&Claypool Publishers, 2011. Citado na página 31.
- CHERVONENKIS, A.; VAPNIK, V. *Theory of Pattern Recognition*. Moscow: Nauka, 1974. Citado na página 26.
- CHIERICI, C. et al. A new approach for analyzing rotated textures. *In Anais do IX Workshop de Visão Computacional*, 2013. Citado 3 vezes nas páginas 19, 25 e 35.
- CORTES, C.; VAPNIK, V. *Support-Vector Networks*. Holmdel: Kluwer Academic Publishers, 1995. Citado na página 26.
- DEAN, J. C.; ILVENTO, C. C. Improved cancer detection using computer-aided detection with diagnostic and screening mammography: prospective study of 104 cancers. *American Journal of Roentgenology*, v. 187, p. 20–28, 2006. Citado 2 vezes nas páginas 17 e 22.
- D’ORSI, E. C. J. *ACR BI-RADS R Atlas, Breast Imaging Reporting and Data System*. [S.l.], 2011. Citado na página 22.
- ELMORE, J. G. et al. International variation in screening mammography interpretations in community-based programs. *J Natl Cancer Inst.*, v. 95(18), p. 1384–1393, 2003. Citado na página 17.
- FERRAZ, C. T.; PEREIRA, O.; GONZAGA, A. Feature description based on center-symmetric local mapped patterns. *In Proceedings of the 29th Annual ACM Symposium on Applied Computing. SAC '14. New York, NY, USA: ACM*, p. 39–44, 2014. Citado 3 vezes nas páginas 19, 25 e 35.
- FERRAZ, C. T.; PEREIRA, O.; GONZAGA, A. Feature description based on mean local mapped pattern. *In Anais do X Workshop de Visão Computacional - WVC 2014*, p. 32–37, 2014. Citado 3 vezes nas páginas 19, 25 e 35.
- FERRAZ, C. T. et al. Object recognition based on bag of features and a new local pattern descriptor. *International Journal of Pattern Recognition and Artificial Intelligence*, v. 28, n. 08, p. 1455010, 2014. Citado 4 vezes nas páginas 18, 19, 25 e 35.

- GAUR, S. et al. Architectural distortion of the breast. *American Journal of Roentgenology*, v. 201, p. 662–670, 2013. Citado na página 17.
- GOLD, R. H.; BASSET, L. W. Radiologic history exhibit. p. 1111–1131, 1990. Citado na página 21.
- GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*. [S.l.]: Prentice Hall, 2008. Citado na página 23.
- HEATH, M. et al. The digital database for screening mammography. in *Proceedings of the 5th international workshop on digital mammography*, p. 212–218, 2000. Citado 3 vezes nas páginas 32, 33 e 34.
- INCA - Instituto Nacional do Câncer. 2017. <<http://www2.inca.gov.br/wps/wcm/connect/inca/portal/home>>. Citado na página 21.
- JASIONOWSKA, M.; PRZELASKOWSKI, A. A two-step method for detection of architectural distortions in mammograms. *Information Technology in Biomedicine*, v. 69, p. 73–84, 2010. Citado 2 vezes nas páginas 18 e 32.
- KAMRA, A.; JAIN, V. K. Enhancement of subtle signs in mammograms using multiscale morphological approach. In *IEEE Point-of-Care Healthcare Technologies (PHT)*, p. 16–18, 2013. Citado na página 18.
- KARELLAS, A.; VEDANTHAM, S. Breast cancer imaging: a perspective for the next decade. *Medical Physics*, v. 35(11), p. 4878–4897, 2008. Citado na página 17.
- KERAMIDAS, E. G. et al. Thyroid texture representation via noise resistant image features. In *Paper presented at the twenty-first IEEE international symposium on computer-based medical systems (CBMS 2008)*, 2008. Citado na página 23.
- LERSKI, R. et al. Mr image texture analysis – an approach to tissue characterisation. *Magnetic Resonance Imaging*, v. 11, p. 873–887, 1993. Citado na página 23.
- LORENA, A. C.; CARVALHO, A. C. P. L. F. de. Introdução às máquinas de vetores suporte. *Technical Report 192, Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, Abril 2003*. Disponível em: <ftp://ftp.icmc.usp.br/pub/BIBLIOTECA/rel_tec/RT_192.ps.zip>. Citado 3 vezes nas páginas 28, 30 e 31.
- LORIS, N.; ALESSANDRA, L.; SHERYL, B. Survey on lbp based texture descriptors for image classification. *Expert Systems with Applications*, v. 39(3), p. 3634–3641, 2012. Citado na página 23.
- MATERKA, A.; STRZELECKI, M. Texture analysis methods – a review. 1998. Citado na página 23.
- NEGRI, T.; GONZAGA, A. Color texture classification by a local multiscale descriptor. In *Anais do XI Workshop de Visão Computacional - WVC 2015*, 2014. Citado 3 vezes nas páginas 19, 25 e 35.
- OJALA, T.; PIETIKAINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on feature distributions. *Pattern Recognition*, v. 29, n. 1, p. 51–59, 1996. Citado 2 vezes nas páginas 18 e 23.

OJALA, T.; PIETIKAINEN, M.; MAENPAA, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 24(7), p. 971–987, 2002. Citado na página 18.

OLIVEIRA, H. C. R. et al. Detection of architectural distortion in digitized screen-film mammograms using texture descriptors. *Escola de Engenharia de São Carlos (EESC). Departamento de Engenharia Elétrica e de Computação, Universidade de São Paulo (USP)*, 2016. Citado 3 vezes nas páginas 19, 32 e 33.

OLIVEIRA, H. C. R. et al. A new texture descriptor based on local micro-pattern for detection of architectural distortion in mammographic images. *in [Proc. of SPIE]*, p. 10134, 2017. Citado 2 vezes nas páginas 19 e 63.

OLIVER, A. et al. False positive reduction in mammographic mass detection using local binary patterns. *In Medical image computing and computer-assisted intervention (miccai), lecture notes in computer science*, Brisbane, Australia: Springer, v. 1, p. 286–293, 2007. Citado na página 23.

PASSERINI, A. *Kernel Methods, Multiclass Classification and Applications to Computational Molecular Biology*. Tese (Doutorado) — Università Degli Studi Di Firenze, 2004. Citado na página 29.

RAY, K. M. et al. Suspicious findings at digital breast tomosynthesis occult to conventional digital mammography: Imaging features and pathology findings. *The Breast Journal*, p. 1–5, 2015. Citado 3 vezes nas páginas 17, 22 e 34.

ROSENFELD, A.; KAK, A. Digital picture processing. Academic Press, v. 1, 1982. Citado na página 23.

SIM - Sistema de Informação sobre Mortalidade. 2017. <<http://sim.saude.gov.br/default.asp>>. Citado na página 21.

SMOLA, A. J. et al. *Introduction to Large Margin Classifiers*. [S.l.]: Kluwer Academic Publishers, 1999. Citado na página 26.

STRZELECKI, M. *Segmentation of Textured Biomedical Images Using Neural Networks*. Tese (Doutorado) — Technical University of Lodz, Poland, 1995. Citado na página 23.

VAPNIK, V. *Statistical Learning Theory*. [S.l.]: John Wiley and Sons, 1995. Citado 2 vezes nas páginas 26 e 27.

VIEIRA, R. T. et al. Local fuzzy pattern: A new way for micro-pattern analysis. *Berlin, Heidelberg: Springer Berlin Heidelberg*, p. 602–611, 2012. Citado 4 vezes nas páginas 18, 19, 25 e 35.

YANG, S. K. et al. Screening mammography-detected cancers: Sensitivity of a computer-aided detection system applied to full-field digital mammograms. *Radiology*, v. 244, n. 1, p. 104–111, 2007. Citado na página 22.