

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
DEPARTAMENTO DE TELEMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Murillo Barata Rodrigues

**Uma nova abordagem para classificação da malignância de nódulos
pulmonares utilizando Matriz de Coocorrência Estrutural**

Fortaleza – CE

31 de Agosto de 2017

Murillo Barata Rodrigues

Uma nova abordagem para classificação da malignância de nódulos pulmonares utilizando Matriz de Coocorrência Estrutural

Dissertação submetida ao Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Área de Concentração: Inteligência Artificial

Orientador: Prof. Dr. Pedro Pedrosa Rebouças Filho

Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Fortaleza – CE

31 de Agosto de 2017

Dados Internacionais de Catalogação na Publicação
Instituto Federal do Ceará - IFCE
Sistema de Bibliotecas - SIBI
Ficha catalográfica elaborada pelo SIBI/IFCE, com os dados fornecidos pelo(a) autor(a)

R696n Rodrigues, Murillo Barata.

Uma nova abordagem para classificação da malignância de nódulos pulmonares utilizando Matriz de Coocorrência Estrutural / Murillo Barata Rodrigues. - 2017.
70 f. : il. color.

Dissertação (Mestrado) - Instituto Federal do Ceará, Mestrado em Ciência da Computação, Campus Fortaleza, 2017.

Orientação: Prof. Dr. Pedro Pedrosa Rebouças Filho.

1. Nódulos Pulmonares. 2. Câncer Pulmonar. 3. Matriz de Coocorrência Estrutural. 4. Classificação de Malignância. I. Título.

CDD 004


MURILLO BARATA RODRIGUES

Uma nova abordagem para classificação da malignância de nódulos pulmonares utilizando
Matriz de Coocorrência Estrutural


Dissertação submetida à Coordenação do Curso de Pós-graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial para a obtenção do título de Mestre em Ciência da Computação, área de concentração Ciência da Computação.

Aprovada em 31 / 08 / 2017.


BANCA EXAMINADORA



Prof. Dr. Pedro Pedrosa Rebouças Filho (Orientador)
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - PPGCC/IFCE



Prof. Dr. Geraldo Luis Bezerra Ramalho
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE



Prof. Dr. Antônio Carlos da Silva Barros
Universidade de Fortaleza (UNIFOR)

*Este trabalho é dedicado aos meus pais, às minhas irmãs e à minha namorada,
por todo apoio, incentivo e conselhos.*

Agradecimentos

A Deus, acima de tudo;

À minha família, a qual me ensina e me incentiva a ser uma pessoa melhor, dia após dia;

À minha amada companheira, Sarah, por ser um apoio constante em minha vida;

Ao Prof. Dr. Pedro Pedrosa, que, ao longo de muito tempo, tem me orientado com atenção e paciência. Obrigado pelos ensinamentos, confiança e amizade;

A todos os meus amigos do PPGCC, do Laboratório de Processamento de Imagens e Simulação Computacional (LAPISCO) e do Laboratório de Inteligência Artificial (LIA);

A todos os professores do mestrado, que, de alguma forma, contribuíram para minha formação;

A todos que colaboraram, direta ou indiretamente, na elaboração deste trabalho;

A todos citados anteriormente, agradeço por fazerem parte da minha vida e por marcarem, de forma positiva, esta etapa.

*“O sucesso nasce do querer, da determinação e persistência em se chegar a um objetivo.
Mesmo não atingindo o alvo, quem busca e vence obstáculos, no mínimo fará coisas
admiráveis”
(José de Alencar)*

Resumo

O câncer de pulmão é considerado a maior causa de morte por câncer no mundo. A fim de reduzir essa taxa de mortalidade, diversos sistemas de auxílio ao diagnóstico médico são desenvolvidos. De forma a contribuir com esse avanço, esta dissertação apresenta uma nova abordagem para a classificação de nódulos pulmonares quanto à malignância. Esta abordagem consiste em utilizar o extrator de características Matriz de Coocorrência Estrutural (*Structural Co-occurrence Matrix*, SCM) em imagens de nódulos e fornecer as características obtidas a um classificador, o qual foi utilizado para rotular o nódulo em análise como maligno ou benigno e para indicar o nível de malignância do mesmo. Os exames de Tomografia Computadorizada (TC) utilizados neste trabalho são provenientes da base de imagens *Lung Image Database Consortium and Image Database Resource Initiative* (LIDC/IDRI), a qual fornece a posição e o nível de malignância dos nódulos para cada exame. A fim de obter a melhor performance do extrator SCM, o mesmo foi aplicado em imagens com intensidades de *pixels* em níveis de cinza variando de 0 a 255 e em Unidades Hounsfield (UH). Além dos dois tipos de imagem, a SCM foi utilizada com os filtros da média, laplaciano, gaussiano e sobel, tanto nas imagens em níveis de cinza quanto em UH, resultando em oito configurações diferentes desse extrator. Em relação a etapa de classificação, os classificadores *Perceptron* Multicamadas (*Multilayer Perceptron*, MLP), Máquina de Vetores de Suporte (*Support Vector Machine*, SVM) e *K*-vizinhos mais próximos (*K-nearest Neighbors*, *K*-NN) são aplicados. A fim de validar a aplicação do extrator SCM, o mesmo tem seus resultados comparados aos dos extratores Matriz de coocorrência de tons de cinza (*Gray-Level Co-occurrence Matrix*, GLCM), Padrões binários locais (*Local Binary Patterns*, LBP), Momentos centrais (MC) e Momentos estatísticos (ME). Além dessa comparação, outros resultados da literatura são apresentados e comparados. Tanto na classificação dos nódulos em maligno ou benigno e em níveis de malignância, a SCM mostrou-se como a melhor abordagem, alcançando 96,7% de acurácia e de F-Score na classificação binária e 74,5% de acurácia e 53,2% de F-Score na classificação multiclasse. Com esses resultados, o uso da SCM para a classificação da malignância de nódulos se mostra eficiente, além de possuir bons tempos de aplicação, podendo ser utilizado como uma ferramenta de auxílio ao diagnóstico médico, contribuindo para que especialistas conquistem resultados mais rápidos e mais precisos.

Palavras-chave: Nódulos Pulmonares, Câncer Pulmonar, Matriz de Coocorrência Estrutural, Classificação de Malignância.

Abstract

Lung cancer is considered the leading cause of death globally. Several computer-aided diagnosis systems are developed in order to reduce lung cancer mortality rate. This dissertation presents a new approach to classify lung nodules malignancy. Such approach consists in performing Structural Co-occurrence Matrix (SCM) to extract features from nodules images and classifying them into malignant or benign nodules and into malignancy levels. The computed tomography (CT) exams from Lung Image Database Consortium and Image Database Resource Initiative (LIDC/IDRI) dataset give information about the nodules position and its malignancy level. The SCM is applied on both gray-scale and Hounsfield units (HU) images with 4 filters, to wit, mean filter, Laplace, Gaussian and Sobel comprehending eight different configuration. Related to the classification stage, the well-known classifiers multilayer perceptron (MLP), support vector machine (SVM) and K -nearest neighbors algorithm (k -NN) were chosen and applied in two tasks: (i) to classify nodules images into malignant or benign nodules and (ii) to classify lung nodules malignancy. The approach results were compared to methods for feature extraction: the gray-level co-occurrence matrix (GLCM), local binary patterns (LBP), central moments (CM) and statistical moment (SM). Moreover, the results were also compared to other ones in literature. Our approach outperformed the other compared methods in both tasks, it achieved 96.7% in the two accuracy and F-Score metrics on the first task, and 74.5% accuracy and 53.2% F-Score on the second one. Therefore, the classification task experiments results revealed that SCM successfully extracted nodules images features and, thus showed itself as a promising tool to support medical decision-making.

Keywords: Pulmonary nodules, Lung Cancer, Structural co-occurrence matrix, Lung Nodules Malignancy Classification.

Lista de ilustrações

Figura 1 – Processo utilizado para criação da GLCM. Fonte: MathWorks (2017) .	28
Figura 2 – Padrão Binário Local determinado para um <i>pixel</i> central, $P(i, j)$. A ordem para a formação do número binário está destacada pela direção da seta (sentido anti-horário, iniciando pelo <i>pixel</i> $P(i - 1, j - 1)$). . . .	30
Figura 3 – Modelo genérico da SCM para dois sinais de entrada. Fonte: Ramalho <i>et al.</i> (2016)	33
Figura 4 – Interpretação da SCM para aplicações em imagens. Fonte: Ramalho <i>et al.</i> (2016)	34
Figura 5 – Hiperplanos (retas) representando algumas das possíveis soluções para um problema binário linearmente separável.	39
Figura 6 – Hiperplanos ótimo, margem de separação (ρ) e vetores de suporte. . . .	39
Figura 7 – Representação de uma rede <i>Perceptron</i> Multicamadas com uma camada oculta.	40
Figura 8 – Etapas do fluxo adotado: preparação dos dados (1), extração de características (2) e classificação (3).	43
Figura 9 – Regiões de Interesse de nódulos malignos (três primeiras colunas) e benignos (três últimas colunas).	44
Figura 10 – Modelo SCM para extração de características em imagens.	45
Figura 11 – Representação de um <i>Perceptron</i> Simples.	69

Lista de tabelas

Tabela 1	– Valores médios de TPR, SPC, PPV, <i>F-Score</i> e ACC para 10 execuções da SCM na classificação binária.	50
Tabela 2	– Tempo médio de treino, teste e extração da SCM e classificadores para a classificação binária.	51
Tabela 3	– Valores médios para a classificação em duas classes (10 iterações) da SCM, GLCM, LBP, MC e ME.	53
Tabela 4	– Tempo médio de treino, teste e extração da SCM, GLCM, LBP, MC, ME e classificadores na classificação binária.	53
Tabela 5	– Matriz de confusão numérica média da SCM Média UH com o classificador SVM.	54
Tabela 6	– Trabalhos relacionados.	55
Tabela 7	– Valores médios de TPR, SPC, PPV, <i>F-Score</i> e ACC para 10 execuções da SCM na classificação multiclasse.	56
Tabela 8	– Tempo médio de treino, teste e extração da SCM e classificadores para a classificação multiclasse.	57
Tabela 9	– Valores médios (10 execuções) de TPR, SPC, PPV, <i>F-Score</i> e ACC da SCM, GLCM, LBP, MC e ME na classificação multiclasse.	58
Tabela 10	– Tempo médio de treino, teste e extração da SCM, GLCM, LBP, MC, ME e classificadores na classificação multiclasse.	59

Lista de abreviaturas e siglas

ACC	Acurácia (<i>Accuracy</i>)
CAD	Diferença Absoluta Complementar (<i>Complementary Absolute Difference</i>)
CAD	Diagnóstico Auxiliado por Computador (<i>Computer-aided diagnosis</i>)
CADe	Sistemas de detecção
CADx	Sistemas de diagnóstico
COR	Correlação
CSD	Distância Chi-quadrada (<i>Chi-square Distance</i>)
CSR	Relação de distância Chi-quadrada (<i>Chi-square Distance Ratio</i>)
D_{KL}	Divergência de Kullback e Leibler
ENT	Entropia
FN	Falso Negativo
FP	Falso Positivo
HL	Camada Oculta (<i>Hidden Layer</i>)
IA	Inteligência Artificial
KNN	K -Vizinhos mais próximos (<i>K-Nearest Neighbors</i>)
LBP	Padrões Binários Locais (<i>Local Binary Patterns</i>)
MC	Momentos Centrais
MDI	Momento da Diferença Inversa
MDR	Taxa de diferença absoluta média (<i>Mean Absolute Difference Ratio</i>)
ME	Momentos Estatísticos
MLP	Perceptron Multicamadas (<i>Multilayer Perceptron</i>)
PDI	Processamento Digital de Imagens
PPV	Valor Preditivo Positivo (<i>Positive Predictive Value</i>)

PS	Perceptron Simples
RNA	Redes Neurais Artificiais
SCM	Matriz de Coocorrência Estrutural (<i>Structural Co-occurence Matrix</i>)
SPC	Especificidade (<i>Specificity</i>)
SVM	Máquinas de Vetores de Suporte (<i>Support Vector Machines</i>)
TC	Tomografia Computadorizada
TPR	Taxa de verdadeiro positivo (<i>True Positive Rate</i>)
UH	Unidades Hounsfield
UT	Unidades de Textura
VC	Visão Computacional
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

Sumário

1	INTRODUÇÃO	23
1.1	Motivação	24
1.2	Trabalhos Relacionados	24
1.3	Objetivos	25
1.3.1	Objetivos Específicos	25
1.4	Produção Científica	26
1.5	Organização da Dissertação	26
2	EXTRATORES DE CARACTERÍSTICAS	27
2.1	Matriz de Coocorrência de Níveis de Cinza	27
2.2	Padrões Binários Locais	29
2.3	Momentos	30
2.3.1	Momentos Estatísticos	30
2.3.2	Momentos Centrais	31
2.4	Matriz de Coocorrência Estrutural	32
2.4.1	Atributos da Matriz de Coocorrência Estrutural	33
3	CLASSIFICADORES	37
3.1	Máquina de Vetores de Suporte	37
3.2	<i>Perceptron</i> Multicamadas	40
3.3	<i>K</i>-Vizinhos mais Próximos	41
4	MATERIAIS E MÉTODOS	43
4.1	Preparação dos Dados	43
4.2	Extração de Características	45
4.3	Classificação	45
4.4	Avaliação de Desempenho	47
5	RESULTADOS E DISCUSSÕES	49
5.1	Classificação de nódulos em benignos e malignos	49
5.1.1	Configuração ótima para classificação de nódulos	49
5.1.2	Comparação com outros extratores de características	52
5.1.3	Comparação com outras abordagens de classificação de nódulos pulmonares	54
5.2	Classificação de nódulos em níveis de malignância	55
5.2.1	Configuração ótima para classificação de nódulos	56
5.2.2	Comparação com outros extratores de características	57

5.3	Análise geral dos resultados	59
6	CONCLUSÃO	61
6.1	Trabalhos Futuros	61
	REFERÊNCIAS	63
	APÊNDICES	67
	APÊNDICE A – <i>PERCEPTRON</i> SIMPLES	69

1 Introdução

As causas mais comuns de morte por câncer são câncer de pulmão, próstata (em homens), mama (em mulheres) e cólon. Estas quatro enfermidades representam 46% de todas as mortes por câncer, com mais de um quarto (27%) devido ao câncer de pulmão (SIEGEL; MILLER; JEMAL, 2016).

Nos países desenvolvidos, os pacientes diagnosticados com essa patologia pulmonar têm uma taxa de sobrevivência de 5 anos entre 10 e 16% (VALENTE *et al.*, 2016). No entanto, há uma perspectiva de melhoria nas taxas de sobrevivência ao câncer de pulmão devido a uma detecção precoce através de exames de Tomografia Computadorizada (TC) (SIEGEL; MILLER; JEMAL, 2016). Nesses casos, a taxa de sobrevivência de cinco anos aumenta para 70% (CAMARLINGHI, 2013).

A partir de exames de TC, imagens de órgãos e de suas estruturas internas são obtidas, a fim de que o médico possa realizar a detecção e o diagnóstico de doenças (REBOUÇAS FILHO, 2013).

Visando reduzir o tempo de análise de exames médicos bem como aumentar a acurácia dos diagnósticos, sistemas de Visão Computacional (VC) utilizam técnicas de Processamento Digital de Imagens (PDI) e de Inteligência Artificial (IA) para reconhecer as estruturas internas das imagens de TC. Assim, é possível prover um auxílio ao especialista em suas interpretações (SILVA, 2004; LI; LIU; FOX, 2005; FELIX; CORTEZ; HOLANDA, 2008; REBOUÇAS FILHO, 2013; BARROS, 2016).

Sistemas de VC geralmente são divididos em 5 etapas consecutivas: aquisição de imagens, pré-processamento, segmentação, extração de atributos e classificação (GONZALEZ; WOODS, 2010). A aquisição de imagens consiste no processo de captura da imagem. O pré-processamento é a etapa responsável pelo condicionamento das imagens para a etapa de segmentação, a qual consiste em obter um objeto ou região de interesse da imagem em análise. A extração de características consiste na obtenção de informações relevantes, capazes de descrever os objetos segmentados. Por fim, a etapa de classificação define a qual classe um objeto pertence, através das características do mesmo (REBOUÇAS FILHO, 2013).

Esta dissertação realiza uma análise de imagens de TC do tórax a fim de classificar nódulos pulmonares de acordo com suas malignâncias.

1.1 Motivação

Após a identificação de um nódulo pulmonar através da TC, o especialista deve listar os diagnósticos possíveis baseado na análise morfológica do nódulo e do contexto clínico. No entanto, os radiologistas têm de avaliar um grande número de nódulos diariamente e gerar diagnósticos em um tempo rápido. Assim, uma pressão surge sobre os mesmos, tornando essa tarefa onerosa (HAN *et al.*, 2013; KUMAR; WONG; CLAUSI, 2015; VALENTE *et al.*, 2016).

A classificação automática dos nódulos entre maligno e benigno, utilizando imagens de TC, visa facilitar a avaliação do estado do nódulo pelo radiologista, contribuindo para um melhor planejamento terapêutico individual (SHEN *et al.*, 2015).

A fim de contornar esse problema, sistemas de diagnósticos auxiliados por computador (*computer-aided diagnosis*, CAD) são desenvolvidos. Os sistemas CAD podem ser divididos em dois tipos: sistemas de detecção (CADE) e sistemas de diagnóstico (CADx).

Em um sistema CADx, o objetivo é realizar um diagnóstico automático baseado nas características extraídas das imagens fornecidas ao sistema (VALENTE *et al.*, 2016). Além disso, um CADx pode ser utilizado como uma segunda opinião, auxiliando a análise do especialista e tornando-a mais precisa (KUMAR; WONG; CLAUSI, 2015).

Visando maximizar o desempenho de um sistema CADx, voltado para o diagnóstico de nódulos pulmonares quanto à malignância, este trabalho investiga extratores de características clássicos e do estado-da-arte, com foco na aplicação do extrator de características Matriz de Coocorrência Estrutural (*Structural Co-occurrence Matrix*, SCM) (RAMALHO *et al.*, 2016).

1.2 Trabalhos Relacionados

No trabalho de Krewer *et al.* (2013), uma combinação de características de forma e de textura são utilizadas para a classificação de nódulos pulmonares em malignos e benignos usando diversos classificadores. O autor utiliza 33 casos, dos quais 14 eram malignos e 19 eram benignos. O maior valor de acurácia alcançado foi de 90,91%.

Shen *et al.* (2017) introduzem um modelo de aprendizagem profunda (*deep learning*) da rede neural convolucional multicortes (*Multi-Crop Convolutional Neural Network*, MC-CNN) para resolver a classificação dos nódulos pulmonares. Os autores utilizam 880 nódulos benignos e 495 nódulos malignos, obtidos da base de dados LIDC/IDRI e conseguem resultados com uma acurácia de 87,14%.

Shen *et al.* (2015) propõem uma rede neural convolucional multiescala (*Multi-Scale Convolutional Neural Networks*, MCNN) para a classificação diagnóstica de nódulos, a

qual é robusta em relação às entradas ruidosas e alcançou 86,84% para a classificação de nódulos, além de superar outros descritores de texturas. Em geral, os autores utilizaram 880 nódulos benignos e 495 nódulos malignos do base de dados LIDC/IDRI.

No trabalho de Sergeeva *et al.* (2016), um sistema para a classificação de nódulos pulmonares foi proposto. Esse sistema utiliza características morfológicas e de textura de regiões de interesse contendo nódulos pulmonares. As características são obtidas a partir da aplicação do extrator matriz de coocorrência de tons de cinza (*Gray Level Co-occurrence Matrix*, GLCM) e da transformada discreta Wavelet em 321 instâncias de nódulos pulmonares da base de dados LIDC.

Kumar, Wong e Clausi (2015) utilizam características profundas (*deep features*) extraídas de um *Autoencoder* para classificar nódulos pulmonares como malignos ou benignos, utilizando 4.303 instâncias contendo 4.323 nódulos do conjunto de dados LIDC.

1.3 Objetivos

Esta dissertação tem como objetivo principal propor o uso do extrator de características Matriz de Coocorrência Estrutural no processo de classificação da malignância de nódulos pulmonares.

1.3.1 Objetivos Específicos

Em um sentido mais específico, esta dissertação possui as seguintes metas:

- obter as regiões de interesse contendo os nódulos a partir da base de imagens *Lung Image Database Consortium and Image Database Resource Initiative* (LIDC/IDRI);
- aplicar o extrator SCM nas regiões de interesse;
- classificar os nódulos em malignos ou benignos e em níveis de malignância, utilizando diferentes configurações da SCM a fim de se encontrar a que alcança os melhores resultados;
- comparar os resultados da aplicação do extrator Matriz de Coocorrência Estrutural com os extratores Matriz de Coocorrência de Tons de Cinza, Padrões Binário Locais, Momentos Centrais e Momentos Estatísticos em ambas classificações;
- comparar os resultados da abordagem proposta com outros trabalhos presentes na literatura;

1.4 Produção Científica

As produções científicas realizadas e aceitas no período de desenvolvimento desta pesquisa foram:

- **RODRIGUES, M.B.; MARINHO, L.B.; NÓBREGA, R.V.M.; SOUZA, J.W.M.; REBOUÇAS FILHO, P.P. Lung Segmentation in Chest Computerized Tomography Images Using the Border Following Algorithm.** International Conference on Intelligent Systems Design and Applications. 53ed. Springer International Publishing, 2017, p.539-548. ISBN 978-3-319-53480-0.
- **NÓBREGA, R.V.M.; RODRIGUES, M.B.; REBOUÇAS FILHO, P.P. Segmentation and visualization of the lungs in three dimensions using 3D Region Growing and Visualization Toolkit in CT examinations of the chest.** In: 30th IEEE International Symposium on Computer-Based Medical Systems - IEEE CBMS 2017, 2017, Thessaloniki, Greece. IEEE International Symposium on Computer-Based Medical Systems - IEEE CBMS 2017. 2017. v. 30.

1.5 Organização da Dissertação

Além deste capítulo introdutório, o qual contém a motivação (Seção 1.1), objetivos (Seção 1.3) e produção científica (Seção 1.4), esta dissertação conta com outros 5 capítulos.

O Capítulo 2 apresenta métodos de extração de características consolidados na literatura, os quais são utilizados a fim de avaliar a abordagem proposta.

No Capítulo 3, os classificadores utilizados nesta pesquisa são apresentados e têm suas metodologias explicadas.

O Capítulo 4 consiste em apresentar a metodologia utilizada nesta pesquisa, explicando as etapas de aquisição de imagens (Seção 4.1), extração de características (Seção 4.2), classificação (Seção 4.3) e as métricas de avaliação de desempenho (Seção 4.4).

No Capítulo 5, os resultados obtidos com a abordagem proposta são apresentados e comparados com os métodos apresentados no Capítulo 2.

Por fim, o Capítulo 6 contém as conclusões do estudo realizado juntamente das propostas para trabalhos futuros.

2 Extratores de Características

Um extrator de características tem como objetivo extrair atributos significativos de uma imagem ou de regiões de interesse da mesma, capazes de representá-las por completo. Esses atributos evidenciam diferenças e similaridades entre imagens. Alguns exemplos de características que podem ser extraídas são: área, contorno, textura, cor, forma, posição, curvatura, entre outros. Com essas informações, pode-se diferenciar um objeto de outro, bem como agrupá-los em um determinado conjunto quando estes possuem características semelhantes.

Diversos métodos são utilizados para extração de características. Assim, faz-se necessária a execução de testes com diversos métodos, de modo a determinar qual o mais eficiente para um determinado problema. Neste sentido, este trabalho considera quatro técnicas, as quais são descritas a seguir.

2.1 Matriz de Coocorrência de Níveis de Cinza

A Matriz de Coocorrência de Níveis de Cinza (*Gray-Level Co-occurrence Matrix*, GLCM) foi proposta por Haralick, Shanmugam e Dinstein (1973) para a extração de atributos de textura. Essa técnica realiza uma análise das coocorrências entre pares de *pixels* relacionados através de uma distância d , também conhecida como espaçamento entre *pixels*, e uma direção θ , a qual pode assumir os valores de 0° , 45° , 90° e 135° . Ao fim dessa análise, uma matriz quadrada é gerada, na qual cada elemento (i, j) registra a frequência de ocorrência de dois *pixels* (um com intensidade i e outro com intensidade j) separados pela distância d na direção θ . Vale ressaltar que o tamanho da matriz de coocorrência é definido pelo número de níveis de cinza, o qual depende de uma função de quantização aplicada sobre a imagem de entrada.

Para exemplificar o funcionamento desta técnica, a Figura 1 mostra a GLCM, com distância $d = 1$ e direção $\theta = 0$ (horizontal), de uma respectiva imagem. Como a imagem possui oito níveis de tons de cinza, a GLCM possui oito *pixels* de largura e de altura. Pode-se observar que o elemento $(1, 1)$ da GLCM é 1 pois há apenas uma ocorrência na imagem de um *pixel* com valor 1 ao lado ($\theta = 0$) de outro *pixel* com valor 1 separados por uma distância $d = 1$. De forma análoga, na linha 1 e coluna 2 da GLCM, têm-se o valor 2, o que indica que existem duas ocorrências de um *pixel* com valor 1 e um *pixel* com valor 2 imediatamente à sua direita. Esse processo é repetido até que a matriz de coocorrência esteja completa, permitindo, assim, que vários descritores de textura sejam calculados. Porém, as características de textura são obtidas a partir da representação normalizada da GLCM.




Figura 1 – Processo utilizado para criação da GLCM. Fonte: MathWorks (2017)

Uma maneira de normalizar a matriz de coocorrência é dividindo o número de vezes que uma coocorrência acontece pelo número total de combinações de coocorrências possíveis, como mostra a equação 2.1:

$$P_{i,j} = \frac{P(i,j)}{\sum_{i=0}^{M_L} \sum_{j=0}^{M_L} P(i,j)}, \quad (2.1)$$

em que M_L é o maior valor de nível de cinza na imagem quantizada.

Haralick, Shanmugam e Dinstein (1973) propuseram 14 medidas estatísticas para se extrair da GLCM, das quais, as principais são:

Energia: ou Segundo Momento Angular, mede a uniformidade da textura, ou seja, a quantidade de repetições de pares de *pixels*.

$$Energia = \sqrt{\sum_{i=0}^L \sum_{j=0}^L G(i,j)^2}. \quad (2.2)$$

Contraste: indica as mudanças abruptas dos níveis de cinza na imagem.

$$Contraste = \sum_{i=0}^L \sum_{j=0}^L |i-j|^2 G(i,j). \quad (2.3)$$

Correlação: analisa a probabilidade conjunta da ocorrência de pares de *pixels* da GLCM, ou seja, mede o quão correlacionado está um *pixel* com seu vizinho.

$$Correlação = \sum_{i=0}^L \sum_{j=0}^L \frac{(i-\mu_i)(j-\mu_j)}{\sigma_i^2 \sigma_j^2} G(i,j). \quad (2.4)$$

Homogeneidade: ou Momento da Diferença Inversa, mede a uniformidade de uma imagem.

$$Homogeneidade = \sum_{i=0}^L \sum_{j=0}^L \frac{G(i,j)}{1+|i-j|^2}. \quad (2.5)$$

Entropia: mede a desordem de uma imagem, ou seja, o grau de desorganização dos níveis de cinza.

$$Entropia = - \sum_{i=0}^L \sum_{j=0}^L P(i, j) \log_2[G(i, j)]. \quad (2.6)$$

Variância: mede a heterogeneidade da textura.

$$Variância = \sum_{i=0}^L \sum_{j=0}^L (i - \mu^2) G(i, j). \quad (2.7)$$

Para as equações descritas acima, $G(i, j)$ representa o valor do conteúdo da GLCM normalizada na coordenada (i, j) ; L representa os níveis de cinza da imagem e $\mu_i, \mu_j, \sigma_i, \sigma_j$ representam a média e o desvio padrão para a linha i e coluna j da matriz de coocorrência normalizada, respectivamente.

2.2 Padrões Binários Locais

Os Padrões Binários Locais (*Local Binary Patterns*, LBP) são descritores de texturas e foram propostos, inicialmente, por Ojala, Pietikainen e Harwood (1994), baseados no trabalho de Wang e He (1990).

Wang e He (1990) introduzem um novo modelo de análise de textura baseado na chamada Unidade de Textura (UT). Uma UT é representada por oito elementos, em que cada um assume um de três possíveis valores (1, 2, 3), obtidos através de uma vizinhança 3×3^1 . A ocorrência de distribuição de unidades de textura, calculada sobre uma região, é chamada de espectro de textura.

Ojala, Pietikainen e Harwood (1994) propõem o uso de uma versão de dois níveis do método de Wang e He (1990), o qual provê uma maneira robusta para a descrição de Padrões Binários Locais (LBP) puros em uma textura.

O método LBP funciona atribuindo um rótulo a cada *pixel*. Este rótulo é representado por um número binário e sua atribuição é feita da seguinte forma: dada uma vizinhança 3×3 de um *pixel* $P(i, j)$, para cada vizinho, verifica-se se este excede ou não um limiar T , o qual é determinado pelo valor do *pixel* central $P(i, j)$, cujo rótulo será determinado. Caso o vizinho em análise exceda ou tenha um valor igual ao limiar T , ele receberá o dígito binário 1, caso contrário, receberá o dígito 0. Após toda a vizinhança 3×3 receber um dígito binário, a junção desses valores representará o *pixel* central, que por sua vez, será um número binário. Visto que a vizinhança é circular, essa junção necessita seguir uma lógica para definir a ordem dos vizinhos na formação do número que será atribuído ao *pixel* central. O número binário atribuído ao *pixel* central será convertido

¹ Uma vizinhança 3×3 de um *pixel* $P(x, y)$ são os *pixels* 8-conectado de $P(x, y)$, ou seja, $P(x-1, y+1)$, $P(x, y+1)$, $P(x+1, y+1)$, $P(x-1, y)$, $P(x+1, y)$, $P(x-1, y-1)$, $P(x, y-1)$ e $P(x+1, y-1)$.

para a base decimal e o resultado dessa conversão é a Unidade de Textura. Vale ressaltar que, como o número binário é convertido para um número decimal, quando se determina a ordem de formação do valor atribuído ao *pixel* central, está se atribuindo um peso a cada um dos vizinhos. Todo esse processo é ilustrado na Figura 2.




Figura 2 – Padrão Binário Local determinado para um *pixel* central, $P(i, j)$. A ordem para a formação do número binário está destacada pela direção da seta (sentido anti-horário, iniciando pelo *pixel* $P(i - 1, j - 1)$).

O LBP é invariante à escala de cinza e pode ser combinado a uma medida de contraste tornando-o mais poderoso. Essa característica é uma das propriedades mais importantes desse extrator, visto que, em diversas aplicações práticas, mudanças monotônicas nos níveis de cinza, as quais podem ser causadas por diferenças de iluminação em um determinado ambiente, são bastante frequentes. Outra característica da primeira versão do LBP é que a mesma é variante à rotação, o que é indesejável em certas aplicações, porém, existem versões do LBP que são invariantes à rotação (OJALA; PIETIKAINEN; HARWOOD, 1994), como a proposta por Ojala, Pietikainen e Maenpaa (2002). A versão do LBP de Ojala, Pietikainen e Maenpaa (2002), é uma formulação genérica, a qual não impõe limite para o tamanho da vizinhança ou para o número de pontos de amostragem.

2.3 Momentos

Momentos foram introduzidos na comunidade de reconhecimento de padrões e de processamento digital de imagens em 1962, com o trabalho de Hu (1962). Desde então, essa técnica tem se tornado um dos mais importantes e mais utilizados descritores de forma, seja como solução ou como um meio de comparação de resultados para novas abordagens (FLUSSER; ZITOVA; SUK, 2009).

2.3.1 Momentos Estatísticos

Em sua definição, Momentos, ou Momentos Estatísticos (ME), são quantidades escalares utilizadas para caracterizar uma função e para capturar suas características significativas. Hu (1962) define os momentos de ordem $(p + q)$ 2-dimensional de uma função

de distribuição de densidade $f(x, y)$ como (HU, 1962):

$$m_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^p y^q f(x, y) dx dy \quad (2.8)$$

em que $p = 0, 1, 2, \dots$ e $q = 0, 1, 2, \dots$.

O momento 2-dimensional de ordem $(p + q)$ de uma imagem digital $I(x, y)$ de tamanho $M \times N$ é definido como (GONZALEZ; WOODS, 2010):

$$m_{pq} = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} x^p y^q I(x, y) \quad (2.9)$$

em que $p = 0, 1, 2, \dots$ e $q = 0, 1, 2, \dots$ são inteiros não-negativos, x e y são as coordenadas do *pixel* em análise e $I(x, y)$ é o valor da tonalidade de cinza do *pixel* (x, y) .

Os Momentos Estatísticos possuem certos significados de acordo com a ordem utilizada. Momentos de baixa ordem, m_{00} , em imagens em tons de cinza, indicam a “massa” da imagem e, em imagens binárias, indicam a área de um objeto. Os momentos m_{01}/m_{00} definem o centroide (ou centro de gravidade) da imagem. Os momentos de segunda ordem, m_{20} e m_{02} , descrevem a “distribuição de massa” da imagem quanto ao eixo das coordenadas (FLUSSER; ZITOVA; SUK, 2009).

2.3.2 Momentos Centrais

Os Momentos Centrais (MC) são computados a partir dos Momentos Estatísticos. Essa abordagem permite que se obtenham momentos invariantes à rotação. Os Momentos Centrais podem ser calculados da seguinte forma (HU, 1962):

$$\mu_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - x_c)^p (y - y_c)^q f(x, y) d(x - x_c) d(y - y_c) \quad (2.10)$$

em que

$$x_c = \frac{m_{10}}{m_{00}} \text{ e } y_c = \frac{m_{01}}{m_{00}}$$

são as coordenadas do centroide do objeto.

Considerando-se $f(x, y)$ uma imagem digital, têm-se a Equação 2.10 em sua forma discreta (GONZALEZ; WOODS, 2010):

$$\mu_{pq} = \sum_x \sum_y (x - x_c)^p (y - y_c)^q f(x, y) \quad (2.11)$$

A partir da Equação 2.11, têm-se que (GONZALEZ; WOODS, 2010):

$$\begin{aligned}
\mu_{00} &= \sum_x \sum_y (x - x_c)^0 (y - y_c)^0 f(x, y) \\
&= \sum_x \sum_y f(x, y) \\
&= m_{00} \\
\mu_{10} &= \sum_x \sum_y (x - x_c)^1 (y - y_c)^0 f(x, y) \\
&= m_{10} - \frac{m_{10}}{m_{00}} (m_{00}) \\
&= 0
\end{aligned} \tag{2.12}$$

Para as primeiras 4 ordens, têm-se (HU, 1962):

$$\begin{aligned}
\mu_{00} &= m_{00} \equiv \mu \\
\mu_{10} &= \mu_{01} \equiv 0 \\
\mu_{11} &= m_{11} - \mu x_c y_c \\
\mu_{20} &= m_{20} - \mu x_c^2 \\
\mu_{02} &= m_{02} - \mu y_c^2 \\
\mu_{21} &= m_{21} - m_{20} y_c + 2m_{11} x_c + 2\mu x_c^2 y_c \\
\mu_{12} &= m_{12} - m_{02} x_c + 2m_{11} y_c + 2\mu x_c y_c^2 \\
\mu_{30} &= m_{30} - 3m_{20} x_c + 2\mu x_c^3 \\
\mu_{03} &= m_{03} - 3m_{02} y_c + 2\mu y_c^3
\end{aligned} \tag{2.13}$$

Por levar em consideração o centro de gravidade em seus cálculos, os Momentos Centrais possuem invariância à rotação, característica essa, necessária em certas aplicações.

2.4 Matriz de Coocorrência Estrutural

A Matriz de Coocorrência Estrutural (*Structural Co-occurrence Matrix*, SCM), proposta por Ramalho *et al.* (2016), mapeia as coocorrências entre as estruturas dos sinais de entrada em um histograma bi-dimensional.

No modelo genérico da SCM, ilustrado na Figura 3, considera-se dois sinais discretos $f \in D_f \subset \mathbb{C}^n$ e $g \in D_g \subset \mathbb{C}^n$ os quais possuem o mesmo número de amostras em cada dimensão. Além disso, considera-se uma função $k: D_g \rightarrow D_f$ que modifica as estruturas do sinal g . Essa função destina-se a elevar as diferenças estruturais entre f e g . No caso de aplicações em imagens, ambos os sinais f e g são imagens em tons de cinza, definidas em $D_f \subset \mathbb{Z}^2$ com dimensões $m \times n$ em que L é o número de níveis. Q é especificado como um algoritmo de agrupamento de N classes ou uma função de quantização de L para N

níveis. Q define a escala das estruturas e limita o tamanho da matriz SCM, reduzindo o custo computacional. A propriedade P expressa o quão similar a intensidade dos *pixels* de f e $k(g)$ quantizados devem ser, a fim de serem contabilizados.




Figura 3 – Modelo genérico da SCM para dois sinais de entrada. Fonte: Ramalho *et al.* (2016)

Dessa forma, a SCM é uma matriz $M = \{m_{i,j}\}$ que armazena a coocorrência das estruturas dos sinais $Q(f)$ e $Q(k(g))$, utilizando a expressão (RAMALHO *et al.*, 2016):

$$m_{i,j} = \#\{(i,j) | P(i,j), i = Q(f_p), j = Q(k(g))_{p+d}\} \quad (2.14)$$

em que, $\#\{\cdot\}$ representa a cardinalidade do subconjunto de pares $(i,j) \in I \times I$ ($I = 0, \dots, N-1$) que satisfaz a propriedade P , com f_p sendo o valor de uma amostra na posição p , e $k(g)_{p+d}$ representando o valor da amostra $k(g)$ dado um deslocamento d .

O modo em que as informações estruturais são armazenadas na SCM é ilustrado na Figura 4. As principais diferenças entre as estruturas de f e $k(g)$ são descritas pelas probabilidades escuras/claras e claras/escuras. Caso a imagem f seja idêntica a imagem $k(g)$, a SCM é diagonal. Caso contrário, com f diferente de $k(g)$, as probabilidades da SCM tendem a ser maiores fora da diagonal, ou seja, nas regiões de transição. Mudanças no valor médio dos *pixels* em g resultam na concentração das probabilidades nas regiões escuras ou nas regiões claras, enquanto alterações no contraste tendem a forçar probabilidades mais altas para as regiões de transição (RAMALHO *et al.*, 2016).

2.4.1 Atributos da Matriz de Coocorrência Estrutural

Um conjunto de atributos escalares, computados a partir da SCM, representam numericamente a informação estrutural armazenada em M . Esses atributos são divididos

Região Escura	Transições Escura/Clara
Transições Clara/Escura	Região Clara

Figura 4 – Interpretação da SCM para aplicações em imagens. Fonte: Ramalho *et al.* (2016)

em três grupos: grupo estatístico, grupo de informação e grupo de divergência (RAMALHO *et al.*, 2016).

Os atributos do grupo estatístico focam no nível de similaridade estrutural armazenado em M (RAMALHO *et al.*, 2016). A Correlação (COR) e o Momento da Diferença Inversa (MDI), ou Homogeneidade, definidos na GLCM, são os atributos desse grupo, porém, foram redefinidos para o âmbito da SCM.

A Correlação, medida estatística do quão correlacionadas as informações estruturais de M são, é calculada da seguinte maneira (RAMALHO *et al.*, 2016):

$$COR = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} m_{i,j} \frac{(i - \mu_i)(j - \mu_j)}{\sqrt{\sigma_i^2 \sigma_j^2}} \in [-1, 1], \quad (2.15)$$

em que μ_i e μ_j são os valores da média das linhas e das colunas de M . σ_i e σ_j são o desvio padrão das linhas e das colunas de M .

O Momento da Diferença Inversa, também conhecido como Homogeneidade, mede a proximidade dos elementos de M à diagonal e é definido por (RAMALHO *et al.*, 2016):

$$MDI = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{m_{i,j}}{1 + (|i - j|)} \in [0, 1]. \quad (2.16)$$

O grupo de informação compreende um atributo que classifica a ordem dos dados em M . Ele mede a aleatoriedade da informação estrutural e é calculado de forma semelhante à Entropia (ENT) da GLCM, sendo definido por (RAMALHO *et al.*, 2016):

$$ENT = - \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} m_{i,j} \log m(i, j). \quad (2.17)$$

Por fim, o grupo de divergência descreve a informação mútua, ou dissimilaridade, entre as distribuições marginais de M , assumindo que seus elementos são variáveis independentes. A primeira divergência é denominada de Distância Chi-quadrada (*Chi-square*

Distance, CSD), dada por (RAMALHO *et al.*, 2016):

$$CSD = \sum_{i=0}^{N-1} \frac{(P_i^0 - P_i^e)^2}{P_i^e} \quad (2.18)$$

com $P_i^0 = m_{i,j} \forall i = j$ e $P_i^e = \sum_{j=0}^{N-1} m_{i,j} \forall j \geq i$.

A segunda divergência, denominada Relação de Distância Chi-quadrada (*Chi-square Distance ratio*, CSR), mede as relações entre as transições escuras e as transições escuras/claras e é calculada da seguinte forma (RAMALHO *et al.*, 2016):

$$CSR = \sum_{i=0}^{N-1} \frac{(P_i^I - P_i^m)^2}{P_i^m}, \quad (2.19)$$

em que $P^m = \frac{(P^I + P^{II})}{2}$, considerando $P^I = \sum_{i=0}^{\frac{N}{2}-1} \sum_{j=0}^{\frac{N}{2}-1} m_{i,j}$ e $P^{II} = \sum_{i=\frac{N}{2}}^{N-1} \sum_{j=\frac{N}{2}}^{N-1} m_{i,j}$.

Para a definição dos próximos atributos, tem-se $P^r = \sum_{j=0}^{N-1} m_j$ como a soma das linhas de M e $P^c = \sum_{i=0}^{N-1} m_i$ como a soma das colunas de M . Assim, pode-se definir mais 3 atributos (RAMALHO *et al.*, 2016):

A divergência de Kullback & Leibler (D_{KL}) é a terceira divergência e ela mede a divergência de informação, ou ganho de informação, entre as distribuições marginais e é obtida por (RAMALHO *et al.*, 2016):

$$D_{KL} = \sum_{i=0}^{N-1} \log \left(\frac{P_i^c}{P_i^r} \right) P_i^c, \quad (2.20)$$

em que $P_i^c/P_i^r = 0$ quando $P_i^r = 0$.

Em seguida, têm-se a Diferença Absoluta Complementar (*Complementary Absolute Difference*, CAD), a qual compara duas distribuições de probabilidade, sendo calculada por (RAMALHO *et al.*, 2016):

$$CAD = 1 - \sum_{i=0}^{N-1} |P_i^c - P_i^r|. \quad (2.21)$$

Por fim, têm-se a Taxa de Diferença Absoluta Média (*mean absolute difference ratio*, MDR). Essa medida compara a dispersão estatística das distribuições marginais de P^c e de P^r . Essa métrica é definida por (RAMALHO *et al.*, 2016):

$$MDR = \frac{MD_1}{MD_2}, \quad (2.22)$$

em que, $MD = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P(s_i)P(s_j)|s_i - s_j|$. s_i , com $i = 0, \dots, N-1$, são os índices dos valores não nulos da distribuição marginal P . $MD_1 = \min(MD_{P^c}, MD_{P^r})$ e $MD_2 = \max(MD_{P^c}, MD_{P^r})$.

3 Classificadores

Na maioria dos sistemas de reconhecimento de padrões, a classificação é a etapa que sucede a extração de características (BISHOP, 2006). Após a obtenção das informações relevantes das imagens, os atributos extraídos são utilizados no processo de classificação das estruturas em análise. Em suma, um classificador tem o objetivo de dividir o espaço de características em regiões que correspondem a uma ou outra classe (DUDA; HART; STORK, 2012).

As técnicas de classificação se dividem, basicamente, em classificação supervisionada, classificação não-supervisionada e classificação semissupervisionada. Na classificação supervisionada, as classes são definidas a partir de exemplos de padrões já determinados, com os quais o classificador é treinado. Nesse tipo de classificação, o aprendizado ocorre através da apresentação de um conjunto de amostras, cujas classes são previamente conhecidas, e da definição de uma função discriminante, a qual é responsável por separar as classes entre si. Na classificação não-supervisionada, os padrões fornecidos ao classificador não possuem informações sobre as classes as quais eles pertencem e, muitas vezes, o número de classes também não é informado. No caso da classificação não-supervisionada, os classificadores são responsáveis por alocar as amostras em diferentes classes, baseados na disposição dessas amostras no espaço de características. A terceira categoria, semissupervisionada, consiste na combinação das outras duas. Nesse tipo de classificação, a aprendizagem é baseada em dados com e sem informações sobre suas classes. Essa abordagem pode ser utilizada quando se tem um número limitado de amostras com informações de suas classes (BISHOP, 2006; THEODORIDIS; KOUTROUMBAS, 2008; DUDA; HART; STORK, 2012).

Neste capítulo, os classificadores supervisionados Máquina de Vetores de Suporte (Seção 3.1), *Perceptron* Multicamadas (Seção 3.2) e *K*-Vizinhos mais Próximos (Seção 3.3) são apresentados.

3.1 Máquina de Vetores de Suporte

Máquina de Vetores de Suporte (*Support Vector Machine*, SVM) é um classificador supervisionado baseado na teoria de aprendizado estatístico, proposta por Vapnik (1998). A ideia básica desse classificador é encontrar um hiperplano de separação ótimo, ou seja, o melhor hiperplano que separa todos os pontos de uma classe de dados dos pontos de outra.

Uma das principais características da SVM, é que o processo de aprendizagem desse classificador tem como objetivo a minimização do risco estrutural (minimização do erro

relacionado aos padrões de teste) além da minimização do risco empírico (minimização do erro associado aos padrões de treinamento), aumentando a capacidade de generalização já na etapa de treinamento (ROCHA NETO, 2011). Essa característica diferencia classificadores SVM de diversos classificadores de aprendizagem tradicional, como a rede *Perceptron* Multicamadas (Seção 3.2).

A SVM objetiva a resolução de problemas binários. Para problemas multiclasse, as abordagens um-contra-um (DUAN; KEERTHI, 2005) e um-contra-todos (DUAN; KEERTHI, 2005), são as mais utilizadas, mesmo havendo formulações (CRAMMER; SINGER, 2001) da SVM para esse tipo de problema (ROCHA NETO, 2011).

Formalmente, um classificador SVM tem o objetivo de estimar uma função $f : \mathbb{R}^N \rightarrow \{\pm 1\}$ utilizando um conjunto (ROCHA NETO, 2011):

$$(x_1, d_1), \dots, (x_n, d_n) \in \mathbb{R}^N \rightarrow \{\pm 1\} \quad (3.1)$$

em que x_i e d_i são o vetor de características e a classe da i -ésima amostra, respectivamente (ROCHA NETO, 2011).

O conjunto apresentado na Equação 3.1 é denominado de conjunto de treinamento. Após a função f ser estimada com o conjunto de treinamento, um conjunto de amostras, denominado conjunto de teste, diferentes das utilizadas para estimar f , deve ser classificado de forma correta.

A Figura 5 ilustra como um problema binário linearmente separável pode apresentar diversas soluções. Partindo desse ponto, as soluções para esse tipo de problema podem ser apresentadas através da equação de um hiperplano:

$$w^T x + b = 0 \quad (3.2)$$

em que w é o vetor de pesos e b é o viés (também chamado de *bias*). Os hiperplanos que separam as duas classes devem satisfazer as seguintes regras:

$$\begin{cases} w^T x_i + b \geq a & \text{para } d_i = +1, \\ w^T x_i + b \leq -a & \text{para } d_i = -1. \end{cases} \quad (3.3)$$

em que $a > 0$ e $i = 1, 2, \dots, n$. Assim, as restrições são satisfeitas para todos os padrões do conjunto de treinamento.

O objetivo de um classificador SVM é encontrar, dentre os hiperplanos possíveis, um hiperplano que tenha a máxima distância em relação aos padrões mais próximos do conjunto de treinamento. Esse hiperplano é denominado hiperplano ótimo. Além deste, têm-se, também, a margem de separação ρ , a qual representa a menor distância entre o hiperplano ótimo e o padrão de treinamento mais próximo (Vetores de Suporte).

A Figura 6 contém um exemplo de um hiperplano ótimo com margem de separação entre duas classes.

Com relação aos problemas que não são linearmente separáveis, os classificadores SVM utilizam funções de *kernel* para a resolução destes. As funções de *kernel* possibilitam que os vetores de entrada sejam projetados em um espaço com uma dimensão mais alta. Isso é feito pois, em um espaço dimensional mais alto, a probabilidade de que o problema em questão se torne linearmente separável é maior. As funções de *kernel* mais utilizadas são: Linear, Polinomial e Função de Base Radial (*Radial Basis Function*, RBF).




Figura 5 – Hiperplanos (retas) representando algumas das possíveis soluções para um problema binário linearmente separável.




Figura 6 – Hiperplanos ótimo, margem de separação (ρ) e vetores de suporte.

3.2 *Perceptron* Multicamadas

A rede *Perceptron* Multicamadas (*Multilayer Perceptron*, MLP) foi desenvolvida com o objetivo de superar algumas limitações da rede *Perceptron* Simples (PS), detalhada no Apêndice A, solucionando problemas cujos padrões não são linearmente separáveis.

Segundo Haykin (1999), uma rede MLP é constituída por um conjunto de unidades de entrada, as quais recebem os sinais, uma ou mais camadas ocultas (*Hidden Layer*, HL), compostas por neurônios não-lineares, e uma camada de saída, composta por um ou mais neurônios que podem ser lineares ou não-lineares. Haykin (1999) também afirma que os neurônios das camadas intermediárias são chamados de neurônios ocultos ou escondidos pelo fato de não se conectarem diretamente à saída da rede. A Figura 7 contém um modelo MLP com uma camada oculta.




Figura 7 – Representação de uma rede *Perceptron* Multicamadas com uma camada oculta.

Na Figura 7, a rede MLP apresenta interligações entre os neurônios das diferentes camadas e, em cada ligação, um valor numérico chamado de peso sináptico é associado.

As camadas ocultas são aquelas que não fazem parte da entrada ou da saída da rede, mas que a tornam capaz de extrair características mais representativas, possibilitando a resolução de problemas não linearmente separáveis. O número de camadas ocultas, bem como o número de neurônios em cada camada e a função de ativação, constituem a arquitetura da rede MLP.

Não há uma regra geral na literatura que defina o número de camadas ocultas e a quantidade de neurônios em cada camada. Em geral, para a maioria dos problemas, uma camada oculta é suficiente e, a respeito da quantidade de neurônios, essa modelagem deve ser definida com base na complexidade do problema.

Em termos de função de ativação, têm-se que a mesma deve ser não-linear nas camadas intermediárias para que o tratamento de não-linearidade seja incorporado à rede.

As funções de ativação mais utilizadas no MLP são as sigmoidais, tais como a função logística (com saída $[0, 1]$) e a função tangente hiperbólica (com saída $[-1, 1]$).

Assim como o PS, o MLP possui as etapas de treinamento e de execução. Apesar da aprendizagem ser supervisionada, a fase treinamento da rede MLP é bastante diferente do treinamento de uma rede PS, visto que as regras de aprendizagem são mais complexa devido a presença de camadas ocultas. O algoritmo de treinamento de redes MLP mais popular é o algoritmo do gradiente descendente de retropropagação do erro, também conhecido como *backpropagation*.

O *backpropagation* é um algoritmo baseado no aprendizado por correção de erros e, em seu funcionamento, ele consegue propagar a informação de erro da camada de saída para as camadas intermediárias. O treinamento de uma rede MLP utilizando o algoritmo *backpropagation* consiste em duas fases: *forward phase* (fase para frente) e *backward phase* (fase para trás) (HAYKIN, 1999). Na fase para frente, *forward*, os pesos sinápticos da rede são fixados e o sinal de entrada é propagado através da rede, camada por camada, até atingir a saída. Assim, nesta fase, as mudanças são restritas aos potenciais de ativação e as saídas dos neurônios na rede (HAYKIN, 1999). Na fase para trás, *backward*, um sinal de erro é produzido pela comparação da saída da rede com uma resposta desejada. O sinal de erro resultante é propagado através da rede, novamente, camada por camada, mas desta vez, a propagação é feita na direção contrária, para trás. Nesta segunda fase, os ajustes sucessivos são feitos para os pesos sinápticos da rede (HAYKIN, 1999).

Durante a etapa de teste, um novo conjunto de dados é apresentado a rede, os quais também possuem as informações da saída desejada. Os resultados obtidos pela rede MLP previamente treinada é comparado aos resultados desejados a fim de avaliar o desempenho da rede. O valor do erro calculado com os dados de teste é denominado erro de generalização da rede, o qual, por sua vez, geralmente é maior que o erro de treinamento, visto que trata-se de um novo conjunto de dados (HAYKIN, 1999).

3.3 *K-Vizinhos mais Próximos*

O algoritmo do vizinho mais próximo possui uma simplicidade conceitual e computacional além de ser um classificador não-paramétrico, visto que ele não faz nenhuma suposição sobre a distribuição dos dados (DUDA; HART; STORK, 2012).

O processo de classificação utilizado pelo *K-Vizinhos mais Próximos* (*K-Nearest Neighbor*, *K-NN*) consiste em considerar cada elemento de um conjunto de treinamento D um ponto em um espaço n -dimensional a fim de fornecer uma noção de distância entre as amostras. Cada elemento de D é uma tupla $(x_1, x_2, x_3, \dots, x_n, c)$ em que c é o rótulo que indica a classe dessa tupla. Assim, dado uma nova tupla $Y = (y_1, y_2, \dots, y_n)$, ainda não classificada, o *K-NN*, a fim de classificá-la, calcula as distâncias de Y para todas as

amostras do conjunto de treinamento D . Em seguida, verifica-se as classes das k tuplas mais próximas. A classe mais frequentes entre as k tuplas mais próximas é atribuída a Y .

Diversas métricas para o cálculo da distância entre dois pontos podem ser utilizadas (Euclidiana, Mahalanobis, Minkowsky, Hamming, entre outras), sendo a distância Euclidiana a mais popular.

Pelo fato de calcular a distância de uma amostra não classificada com todas as amostras do conjunto de treinamento durante o processo de classificação, o K -NN pode ser computacionalmente exaustivo quando um conjunto de dados muito extenso é utilizado.

Com relação ao melhor valor de k , não existe um valor ótimos para solucionar todos os problemas de maneira ótima, assim, k pode ser determinado de forma experimental, através da classificação de um conjunto de testes T para $k = (1, 3, 5, \dots)$ em que k é um inteiro ímpar (a fim de se evitar empate entre as amostras mais próximas). O valor de k que retornar o menor número de amostras classificadas de maneira incorreta pode ser definido como o valor ideal para o problema em questão.

O valor ideal de k é importante, visto que o K -NN pode classificar uma amostra de forma incorreta diante da presença de ruídos ou características irrelevantes. Assim, k não pode assumir um valor muito pequeno em determinados problemas para que o resultado não seja influenciado por ruídos, como também não pode assumir um valor muito alto, visto que a frequência de uma determinada classe diferente da classe correta, pode aumentar entre as amostras mais próximas, fazendo com a classificação seja feita de forma errada.

4 Materiais e Métodos

Nste capítulo serão apresentadas as etapas realizadas no decorrer desta pesquisa, divididas em preparação dos dados (Seção 4.1), extração de características (Seção 4.2) e classificação (Seção 4.3). A Figura 8 contém o fluxo adotado nesta pesquisa.




Figura 8 – Etapas do fluxo adotado: preparação dos dados (1), extração de características (2) e classificação (3).

4.1 Preparação dos Dados

As imagens de nódulos utilizadas neste trabalho foram retiradas dos exames de Tomografia Computadorizada (TC) contidos na base de dados LIDC/IDRI, proposta por Armato *et al.* (2011). Essa base de dados contém 1018 exames de TC do tórax, cada um acompanhado de um arquivo XML associado, o qual possui os resultados de um processo de análise realizado por quatro radiologistas torácicos. Esse processo de análise deu-se em duas etapas, em que durante a primeira, cada radiologista, de forma independente, revisou todos os exames e marcou lesões pertencentes a uma das três seguintes categorias: “nódulo ≥ 3 mm”, “nódulo < 3 mm” e “não-nódulo ≥ 3 mm”. Na segunda etapa, cada radiologista

revisou, também de forma independente, suas anotações acompanhadas das marcações dos outros três radiologistas, a fim de se chegar a um resultado final.

A base LIDC/IDRI possui 7371 lesões marcadas como “nódulo” por pelo menos um radiologista. 2669 dessas lesões foram marcadas como “nódulo ≥ 3 mm” por pelo menos um radiologista, das quais, 987 receberam marcações dos quatro radiologistas (ARMATO *et al.*, 2011).

Os arquivos XML possuem informações sobre algumas características dos nódulos, como “estrutura interna”, “calcificação”, “malignância”, entre outras. Com relação à malignância, uma classificação em uma escala de 5 pontos foi utilizada para indicar a probabilidade de malignidade, ou seja, 5 níveis de malignância, de benigno a maligno. Ressalta-se que o nível de malignância foi especialmente subjetivo, uma vez que os radiologistas não receberam qualquer informação clínica sobre os pacientes. Assim, a probabilidade de malignidade foi avaliada sob o pressuposto de um fumante masculino de 60 anos (ARMATO *et al.*, 2011).

Todas as informações dos nódulos, como suas coordenadas dentro dos exames e suas malignâncias, estão presentes nos arquivos XML da base de dados. Assim, o centroide de cada nódulo foi calculado, baseando-se nas coordenadas informadas, a fim de se obter a região de interesse para a etapa de extração de características.

O centroide de cada nódulo consiste em três valores x , y e z , em que o par ordenado (x, y) corresponde à posição do centro do nódulo na fatia z do exame. A região de interesse obtida a partir desse centroide consiste em uma imagem com dimensões 49×49 cujo centro é o mesmo do nódulo. Alguns exemplos de regiões de interesse de nódulos são mostrados na Figura 9.




Figura 9 – Regiões de Interesse de nódulos malignos (três primeiras colunas) e benignos (três últimas colunas).

4.2 Extração de Características

Esta etapa consiste na aplicação do extrator de características SCM, gerando bases de dados contendo as características de cada região de interesse. O modelo da SCM aplicado é apresentado na Figura 10, em que os dois sinais de entrada são uma mesma imagem e $k(g)$ é a imagem de entrada após a aplicação de um filtro k .

A fim de se obter a melhor configuração da SCM, a mesma foi aplicada com a função k sendo os filtros Gaussiano, Laplaciano, Média e Sobel. Além da variação de filtros, as imagens de entrada foram fornecidas ao extrator em tons de cinza e em Unidades Hounsfield. Dessa maneira, oito bases de dados (SCM Média UH, SCM Gaussiano UH, SCM Laplaciano UH, SCM Sobel, UH SCM Média Cinza, SCM Gaussiano Cinza, SCM Laplaciano Cinza e SCM Sobel Cinza) foram geradas.

Os filtros Gaussiano, Média, Laplaciano e Sobel foram utilizados devido ao fato de serem filtros passa-baixa (Gaussiano e Média) e passa-alta (Laplace e Sobel), suavizando e realçando as saliências das imagens, respectivamente.

Os extratores GLCM, LBP, MC e ME, também são aplicados nas mesmas regiões. Assim, os resultados da SCM são comparados com os resultados desses métodos.




Figura 10 – Modelo SCM para extração de características em imagens.

4.3 Classificação

Após a etapa de extração de características, as oito bases de dados geradas são pré-processadas para, em seguida, serem utilizadas na etapa de classificação. Este pré-processamento realizado consiste em gerar novas bases, com amostras relevantes e rotuladas de acordo com o problema a ser solucionado.

Nesta pesquisa, a classificação dos nódulos realiza-se de duas maneiras: uma considerando duas classes (malingo e benigno) e outra considerando cinco classes, referentes aos cinco pontos utilizados para indicar a probabilidade de malignidade, como explicado na Seção 4.1.

Para a classificação de nódulos em duas classes, os nódulos com valores de probabilidade de malignidade indicados como “1” ou “2” foram rotulados como “benigno”. Já os nódulos com valores “4” ou “5” foram rotulados como “maligno”. Os nódulos com valores iguais a “3” foram desconsiderados devido ao fato deste valor indicar que a malignidade do nódulo correspondente é incerta. Para a classificação em níveis de malignância, cada um dos cinco níveis de probabilidade de malignidade foi considerado como uma classe, ou seja, os nódulos com malignância iguais a “1” foram rotulados como classe “1”, nódulos com malignância iguais a “2” foram rotulados como classe “2” e assim por diante. Dessa maneira, as oito bases geradas passam a ser 16 bases, oito para a classificação binária e oito para a classificação multiclasse.

Após os nódulos terem sido rotulados, realiza-se uma redução na quantidade de amostras das bases a fim de se obter um balanceamento entre o número de elementos das classes. Além disso, tal redução também é feita para que as melhores amostras sejam selecionadas, de forma a contribuir para uma classificação mais correta. A redução foi feita selecionando-se os 500 elementos mais próximos do valor da média de todas as amostras de cada classe. Assim, para o problema da classificação binária, as bases reduzidas consistem em 1000 amostras, das quais 500 são malignas e 500 são benignas. Para a classificação entre as 5 classes, cada classe possui 500 amostras, totalizando 2500 amostras por base.

Com as bases reduzidas, inicia-se as etapas de treinamento e de teste dos classificadores MLP, SVM e K -NN. Os classificadores MLP e SVM foram parametrizados através das técnicas de validação cruzada com 10 *folds* e de busca em grade (*grid search*) (HAYKIN, 2008). A validação cruzada utilizando o método *k-fold* consiste em dividir todo o conjunto de dados em k subconjuntos e, em seguida, considerar um subconjunto como o conjunto de teste e os subconjuntos restantes como o conjunto de treinamento. Essa divisão é realizada em k execuções, sempre alterando o subconjunto que será considerado como conjunto de teste.

Sobre a parametrização dos classificadores, o classificador K -NN considerou a distância Euclidiana e teve o valor de k igual a 5. O classificador SVM foi aplicado com o *kernel* RBF, assim, a busca em grade para este classificador consistiu em encontrar dois parâmetros: C e γ . Essa busca de parâmetros é representada pelas seguintes sequências exponenciais: $C \in [2^{-5}, 2^{-4}, 2^{-3}, \dots, 2^{15}]$ e $\gamma \in [2^{-15}, 2^{-14}, \dots, 2^3]$ (HSU; CHANG; LIN, 2003).

Para a arquitetura do classificador MLP, utiliza-se a busca em grade a fim de se encontrar o número de neurônios na camada oculta em um intervalo de 1 a 50. Outros

parâmetros utilizados para a definição da arquitetura da MLP foram o algoritmo de treinamento, o critério de parada, a taxa de aprendizagem. O algoritmo de treinamento utilizado foi o *back-propagation*. O critério de parada foi definido pelo número de iterações (máximo de 1000) e a taxa de aprendizagem utilizada foi de $\eta = 0.01$.

4.4 Avaliação de Desempenho

Com o objetivo de avaliar o desempenho dos classificadores bem como a diferença entre as bases de dados, as seguintes métricas de avaliação foram utilizadas: acurácia (*accuracy*, ACC), sensibilidade (*True Positive Rate*, TPR), especificidade (*specificity*, SPC), precisão ou valor preditivo positivo (*positive predictive value*, PPV) e F-Score. Essas medidas são obtidas baseadas na matriz de confusão.

A matriz de confusão, também conhecida como matriz de erro, possui quatro categorias: verdadeiro positivo, verdadeiro negativo, falso positivo e falso negativo. Os valores verdadeiro positivo (VP) e verdadeiro negativo (VN) correspondem, respectivamente, à quantidade de amostras positivas e negativas previstas corretamente por um modelo de classificação. O valor falso positivo (FP) corresponde à quantidade de exemplos positivos previstos de maneira incorreta como negativos. Seguindo a mesma ideia, o valor falso negativo (FN) corresponde ao número de exemplos positivos previstos de maneira incorreta como negativos.

Com relação às métricas obtidas a partir dos valores VP, FP, VN e FN, a ACC representa a proporção de amostras classificadas corretamente pela quantidade total de amostras, calculada por:

$$ACC = \frac{VP + VN}{VP + VN + FP + FN} . \quad (4.1)$$

A TPR representa a proporção de amostras positivas classificadas corretamente pela quantidade total de amostras positivas, calculada da seguinte forma:

$$TPR = \frac{VP}{VP + FN} . \quad (4.2)$$

Semelhante à TPR, a SPC é a proporção de amostras negativas classificadas corretamente pela quantidade total de amostras negativas, dada por:

$$SPC = \frac{VN}{VN + FP} . \quad (4.3)$$

A PPV é a proporção entre amostras positivas classificadas corretamente e todas as amostras classificadas como positivas, obtida por:

$$PPV = \frac{VP}{VP + FP} . \quad (4.4)$$

A medida *F-Score* é a média harmônica entre a PPV e a TPR:

$$F\text{-Score} = 2 \cdot \frac{PPV \cdot TPR}{PPV + TPR} = \frac{2VP}{2VP + FP + FN} . \quad (4.5)$$

Todos os testes foram executados em um computador com um processador Intel Core *i5* de 2.4 GHz, memória RAM de 8GB e sistema operacional MacOS X El Capitan 10.11.2. Os extratores (apresentados no Capítulo 2 e na Seção 2.4) e os classificadores (Capítulo 3), foram implementados utilizando a biblioteca computacional OpenCV 3.0.

5 Resultados e Discussões

Este capítulo apresenta e analisa os resultados obtidos pelos classificadores MLP, SVM e K -NN no processo de classificação dos nódulos em maligno e benigno e em níveis de malignância. A análise dos resultados da classificação dos nódulos em maligno e benigno é realizada em três etapas enquanto a da classificação em níveis de malignância é realizada em apenas duas.

A primeira etapa de ambas as classificações consiste em uma comparação entre diferentes configurações da SCM, utilizando os filtros da Média, Gaussiano, Laplaciano e Sobel combinados com os três classificadores anteriormente citados. Além disso, a SCM foi aplicada nas imagens em tons de cinza e em Unidades Hounsfield. Essa etapa é feita com o intuito de se obter a melhor combinação entre imagem de entrada, filtro e classificador.

A segunda etapa de ambas as classificações consiste em realizar uma comparação da SCM com os extratores apresentados no Capítulo 2, também utilizando os três classificadores. Essa etapa tem como objetivo constatar a eficiência do uso da SCM como extrator de características em imagens de nódulos pulmonares, verificando a superioridade de seus resultados diante de alguns extratores comumente utilizados na literatura.

A classificação dos nódulos em maligno e benigno possui uma terceira etapa de análise dos resultados, a qual consiste em comparar a abordagem proposta com outras abordagens da literatura que utilizaram a mesma bases de dados (LIDC/IDRI) e informaram os resultados de acurácia obtidos. As comparações realizadas levam em consideração os resultados dos classificadores e os tempos de execução dos mesmos, bem como os tempos de extração médio para uma amostra de cada extrator.

5.1 Classificação de nódulos em benignos e malignos

Esta seção se destina a apresentar e analisar os resultados do uso da SCM no problema de classificação de nódulos em malignos e benignos.

5.1.1 Configuração ótima para classificação de nódulos

Diversos testes com o extrator SCM foram executados a fim de se encontrar a melhor combinação entre informação de entrada, filtro e classificador. Os testes foram realizados em imagens em tons de cinza e em UH e utilizando quatro diferentes filtros na SCM, que são os filtros da Média, Gaussiano, Laplaciano e Sobel. Os atributos obtidos a partir dos extratores foram fornecidos como entrada para 3 diferentes classificadores: MLP, SVM e K -NN.

Os resultados médios de 10 execuções de todas as combinações são apresentados na Tabela 1 e estão divididos em: acurácia (ACC), sensibilidade (TPR), especificidade (SPC), precisão ou valor preditivo positivo (PPV) e *F-Score*. Nessa tabela, os dois melhores resultados foram destacados em verde e em azul, sendo verde a cor utilizada para destacar o melhor.

Tabela 1 – Valores médios de TPR, SPC, PPV, *F-Score* e ACC para 10 execuções da SCM na classificação binária.

Extrator	Classificador	TPR(%)	SPC(%)	PPV (%)	<i>F-Score</i> (%)	ACC (%)
SCM Média UH	MLP	98,200	92,600	92,992	95,525	95,400
	SVM	98,200	95,200	95,339	96,748	96,700
	<i>K</i> -NN	96,400	94,200	94,324	95,351	95,300
SCM Gaussiano UH	MLP	96,200	79,800	82,646	88,909	88,000
	SVM	98,800	91,800	92,336	95,458	95,300
	<i>K</i> -NN	94,200	92,800	92,899	93,545	93,500
SCM Laplaciano UH	MLP	20,000	80,000	50,000	28,571	50,000
	SVM	57,600	71,000	66,512	61,736	64,300
	<i>K</i> -NN	60,800	69,000	66,230	63,399	64,900
SCM Sobel UH	MLP	52,400	72,000	65,174	58,093	62,200
	SVM	77,200	82,000	81,092	79,098	79,600
	<i>K</i> -NN	78,400	74,200	75,239	76,787	76,300
SCM Média Cinza	MLP	90,000	10,000	50,000	64,285	50,000
	SVM	64,200	56,800	59,776	61,909	60,500
	<i>K</i> -NN	42,400	70,200	58,725	49,245	56,300
SCM Gaussiano Cinza	MLP	60,000	40,000	50,000	54,545	50,000
	SVM	61,200	59,200	60,000	60,594	60,200
	<i>K</i> -NN	48,000	66,800	59,113	52,980	57,400
SCM Laplaciano Cinza	MLP	75,800	59,400	65,120	70,055	67,600
	SVM	54,600	87,400	81,250	65,311	71,000
	<i>K</i> -NN	64,000	74,200	71,269	67,439	69,100
SCM Sobel Cinza	MLP	83,600	65,800	70,967	76,767	74,700
	SVM	83,800	79,800	80,576	82,156	81,800
	<i>K</i> -NN	78,400	80,200	79,837	79,112	79,300

De todas as combinações apresentadas na Tabela 1, a SCM com filtro da Média e a SCM com filtro Gaussiano, ambas aplicadas em regiões de interesse em UH, foram as únicas com acurácia média maior que 90%, com exceção da combinação do extrator SCM Gaussiano com o classificador MLP, que obteve acurácia média de 88%.

A performance da SCM aplicada nas regiões de interesse em tons de cinza não se apresentou como satisfatória, uma vez que resultados com medidas de acurácia maiores que 90% foram alcançados em outras configurações. Os resultados obtidos utilizando regiões de interesse em UH também não foram satisfatórios com a SCM combinada aos filtros Laplace e Sobel, cujos valores médios de acurácia foram abaixo de 80%.

Em uma análise geral da Tabela 1, considerando-se todas as medidas utilizadas, os melhores resultados foram encontrados com o extrator SCM utilizando o filtro da Média e o filtro Gaussiano, ambos aplicados em imagens em UH. Dessas combinações, a SCM

Média UH junta ao classificador SVM foi a melhor combinação encontrada, com os maiores valores de TPR, PPV, F-Score e ACC.

Através dos resultados apresentados na Tabela 1, conclui-se que a escolha do filtro a ser utilizado junto à SCM, bem como as imagens utilizadas, implica de forma relevante nos resultados finais.

As configurações utilizando imagens em UH alcançaram resultados mais altos, uma vez que esse tipo de imagem contém mais informações sobre a variação da intensidade dos *pixels*, melhorando a análise da textura nesse problema de classificação. Os filtros passa-baixa (Gaussiano e Média) obtiveram resultados melhores que os filtros passa-alta (Laplaciano e Sobel), uma vez que filtros passa-baixa removem pequenas estruturas e ruídos, o que contribuiu para uma melhor classificação.

A Tabela 2 contém os valores dos tempos médios de treino e teste de cada classificador para cada extrator juntamente com os tempos de extração médio de uma amostra. Nesta tabela, os dois menores tempos foram destacados em verde e em azul, sendo verde a cor utilizada para destacar o menor.

Tabela 2 – Tempo médio de treino, teste e extração da SCM e classificadores para a classificação binária.

Extrator	Classificador	Tempo de Treino (s)	Tempo de Teste (s)	Tempo de Extração (s)
SCM Média UH	MLP	1,757766 ± 0,946278	0,000001 ± 0,000001	0,0480 ± 0,0041
	SVM	2,029692 ± 0,017843	0,000136 ± 0,000135	
	K-NN	0,000018 ± 0,000002	0,003278 ± 0,003246	
SCM Gaussiano UH	MLP	2,154019 ± 0,738326	0,000001 ± 0,000001	0,0440 ± 0,0046
	SVM	1,994519 ± 0,035163	0,000360 ± 0,000356	
	K-NN	0,000028 ± 0,000018	0,003151 ± 0,003119	
SCM Laplaciano UH	MLP	2,701015 ± 0,170395	0,000001 ± 0,000001	0,0448 ± 0,0040
	SVM	3,365795 ± 0,493034	0,001086 ± 0,001075	
	K-NN	0,000020 ± 0,000002	0,003069 ± 0,003039	
SCM Sobel UH	MLP	2,695329 ± 0,726748	0,000001 ± 0,000001	0,0457 ± 0,0051
	SVM	2,608690 ± 0,068234	0,000589 ± 0,000584	
	K-NN	0,000020 ± 0,000003	0,003257 ± 0,003224	
SCM Média Cinza	MLP	2,225363 ± 0,732661	0,000001 ± 0,000001	0,0488 ± 0,0082
	SVM	2,739410 ± 0,168567	0,000938 ± 0,000929	
	K-NN	0,000017 ± 0,000001	0,002090 ± 0,002069	
SCM Gaussiano Cinza	MLP	3,009984 ± 0,419738	0,000001 ± 0,000001	0,0460 ± 0,0084
	SVM	2,800269 ± 0,257210	0,000973 ± 0,000964	
	K-NN	0,000020 ± 0,000002	0,002575 ± 0,002549	
SCM Laplaciano Cinza	MLP	2,486071 ± 0,062094	0,000001 ± 0,000001	0,0469 ± 0,0084
	SVM	2,797863 ± 0,022985	0,000851 ± 0,000842	
	K-NN	0,000018 ± 0,000002	0,002146 ± 0,002125	
SCM Sobel Cinza	MLP	2,548915 ± 0,113428	0,000001 ± 0,000001	0,0477 ± 0,0087
	SVM	2,515297 ± 0,024407	0,000597 ± 0,000591	
	K-NN	0,000019 ± 0,000004	0,002133 ± 0,002112	

Os valores médios dos tempos de treino e teste são muito similares entre os extratores. Entre os classificadores, o K-NN apresenta sempre o menor tempo médio de treinamento e o maior tempo médio de teste. Com relação aos valores dos tempos de teste, o classificador MLP obteve os menores tempos, seguido pelo classificador SVM.

Entre os classificadores que obtiveram as taxas de acerto mais altas (SCM Média UH, SCM Gaussiano UH e SCM Sobel Cinza), o maior tempo médio de treino foi o do extrator SCM Sobel Cinza junto ao classificador MLP, com 2,55s, e o maior tempo médio de teste foi do extrator SCM Média UH com o classificador K -NN, com 0,003s.

Com relação ao tempo de extração, todos as variações utilizadas da SCM possuem tempos médios semelhantes e em torno de 0,05s. Assim, pode-se concluir que a SCM, combinada a um filtro específico, possui a capacidade de extrair características relevantes de imagens de nódulos pulmonares, contribuindo para que um classificador seja treinado de forma a obter bons resultados em suas classificações.

Assim, com base nos resultados apresentados e nas análises realizadas, têm-se a SCM com filtro da Média, aplicada em imagens em UH, como a melhor abordagem entre as variações do extrator SCM testadas para o problema da classificação de nódulos em malignos e benignos.

5.1.2 Comparação com outros extratores de características

Dado que na Seção 5.1.1 a SCM Média UH foi selecionada como a melhor abordagem para a extração de características de nódulos entre as variações do extrator SCM, nesta seção, essa abordagem é comparada com os extratores GLCM, LBP, MC e ME, todos aplicados nas mesmas imagens de nódulos e utilizando os mesmos classificadores para a validação dos resultados.

Essa comparação é realizada para provar que o extrator SCM possui uma eficiência maior que alguns extratores clássicos utilizados na literatura. A Tabela 3 contém os valores médios de ACC, SPC, PPV e F -Score de 10 execuções para cada extrator combinado a um classificador. Nessa tabela, os dois melhores resultados foram destacados em verde e em azul, sendo verde a cor utilizada para destacar o melhor.

Analisando os resultados apresentados na Tabela 3, dentre os quatro extratores utilizados, o LBP foi o que obteve o valor de ACC mais próximo da SCM, com $\approx 80\%$. Como pode ser visto nesta tabela, os resultados obtidos pelo extrator SCM foram superiores a todos os outros resultados com uma margem alta de diferença. Essa superioridade nos resultados contribui para comprovar a capacidade efetiva do extrator SCM quando utilizado para a classificação de nódulos em malignos e benignos.

A Tabela 4 contém os valores dos tempos médios de extração, de treinamento e de teste para cada extrator e classificador. Nesta tabela, os dois menores tempos foram destacados em verde e em azul, sendo verde a cor utilizada para destacar o menor.

Os menores tempos de treinamento dos classificadores MLP e SVM foram alcançados com as informações obtidas a partir da aplicação do extrator SCM Média UH. Com relação ao tempo de teste, o menor tempo médio utilizando o classificador SVM também foi obtido

Tabela 3 – Valores médios para a classificação em duas classes (10 iterações) da SCM, GLCM, LBP, MC e ME.

Extrator	Classificador	TPR(%)	SPC(%)	PPV (%)	F-Score(%)	ACC (%)
SCM Média UH	MLP	98,200	92,600	92,992	95,525	95,400
	SVM	98,200	95,200	95,339	96,748	96,700
	K-NN	96,400	94,200	94,324	95,351	95,300
GLCM	MLP	51,000	62,000	57,303	53,968	56,500
	SVM	64,600	72,800	70,370	67,361	68,700
	KNN	63,800	70,060	68,400	66,045	67,200
LBP	MLP	68,554	79,918	78,173	73,048	74,100
	SVM	80,800	80,600	80,638	80,719	80,700
	KNN	82,200	65,600	70,497	75,900	73,900
MC	MLP	80,761	51,297	62,287	70,331	66,000
	SVM	84,600	64,000	70,149	76,699	74,300
	KNN	78,200	67,200	70,450	74,123	72,700
ME	MLP	83,000	55,800	65,251	73,063	69,400
	SVM	79,200	75,600	76,447	77,799	77,400
	KNN	67,800	76,400	74,179	70,846	72,100

Tabela 4 – Tempo médio de treino, teste e extração da SCM, GLCM, LBP, MC, ME e classificadores na classificação binária.

Extrator	Classificador	Tempo de Treino (s)	Tempo de Teste (s)	Tempo de Extração (s)
SCM Média UH	MLP	1,757766 ± 0,946278	0,000001 ± 0,000001	0,0480 ± 0,0041
	SVM	2,029692 ± 0,017843	0,000136 ± 0,000135	
	K-NN	0,000018 ± 0,000002	0,003278 ± 0,003246	
GLCM	MLP	2,270910 ± 0,867463	0,000001 ± 0,000001	6,0877 ± 1,0365
	SVM	2,967113 ± 0,024136	0,000868 ± 0,000859	
	K-NN	0,000023 ± 0,000004	0,003399 ± 0,003365	
LBP	MLP	44,048176 ± 1,032490	0,000001 ± 0,000001	0,1747 ± 0,0427
	SVM	16,411175 ± 0,137494	0,005731 ± 0,005673	
	K-NN	0,000116 ± 0,000070	0,010815 ± 0,010707	
MC	MLP	2,420326 ± 0,023988	0,000001 ± 0,000001	0,0053 ± 0,0022
	SVM	2,731912 ± 0,025732	0,000733 ± 0,000726	
	K-NN	0,000016 ± 0,000001	0,002059 ± 0,002038	
ME	MLP	2,621801 ± 0,024428	0,000001 ± 0,000001	0,0054 ± 0,0019
	SVM	3,152975 ± 0,028960	0,000804 ± 0,000795	
	K-NN	0,000018 ± 0,000001	0,002328 ± 0,002304	

com o extrator SCM Média UH, no entanto, o menor tempo médio para o classificador K-NN foi obtido junto ao extrator MC, seguido pelo extrator ME. Os extratores MC e ME obtiveram os menores tempos médios de extração por amostra, aproximadamente 0,0054s, seguidos pela SCM Média UH.

Mesmo que os métodos MC e ME tenham alcançado os menores tempos de extração, a SCM Média UH ainda se mostra uma abordagem melhor, visto que a taxa média de acurácia obtida com a mesma alcançou o valor de 96,7%.

Assim, pode-se concluir que o extrator SCM Média UH possui não só boas taxas de acerto, mas também, uma boa performance de tempo, mostrando-se melhor que os

extratores GLCM, LBP, MC e ME, os quais são abordagens consolidadas na literatura.

A fim de fornecer mais informações sobre os resultados alcançados pela SCM Média UH, a matriz de confusão média obtida a partir de 10 execuções do classificador SVM, treinado e testado com os atributos extraídos pela mesma, é apresentada na Tabela 5.

Tabela 5 – Matriz de confusão numérica média da SCM Média UH com o classificador SVM.

CLASSE	0	1
0	49,1	0,9
1	2,4	47,6

5.1.3 Comparação com outras abordagens de classificação de nódulos pulmonares

Na Seção 5.1.1, a SCM com filtro da Média, aplicada em imagens em unidades *Hounsfield*, chamada SCM Média UH, foi selecionada como a melhor abordagem dentre as variações do extrator SCM, principalmente quando seus resultados são utilizados com o classificador SVM. Na Seção 5.1.2, a SCM Média UH foi comparada a outros extratores comumente utilizados na literatura (GLCM, LBP, MC e ME). Essa comparação se deu através da aplicação de todos os extratores nas mesmas imagens de entrada, a fim de se comprovar a eficiência da SCM.

Nesta seção, os resultados da SCM Média UH são comparados aos resultados obtidos de outras abordagens propostas para a classificação da malignância de nódulos pulmonares. É importante ressaltar que essas outras abordagens utilizam informações sobre os nódulos provenientes da mesma base de dados utilizada neste trabalho (LIDC/IDRI), no entanto, as imagens fornecidas aos extratores são diferentes, visto que o método de seleção das regiões de interesse, as quais contêm os nódulos, varia entre os autores, bem como a quantidade de imagens utilizada em cada trabalho.

A Tabela 6 contém alguns trabalhos relacionados que informaram os valores de acurácia obtidos e a abordagem proposta neste trabalho. Vale ressaltar que, em alguns desses trabalhos, comparações com outros métodos também são realizadas. Estes trabalhos foram selecionados por alcançarem bons resultados, além de serem abordagens recentes.

Através de uma análise dos valores de acurácia apresentados na Tabela 6, constata-se que a SCM Média UH, combinada ao classificador SVM, é uma abordagem eficiente na classificação de nódulos pulmonares em malignos e benignos quando comparada a outros trabalhos propostos.

Tabela 6 – Trabalhos relacionados.

Abordagem	Descrição	Base de dados	Quantidade de Nódulos	Acurácia
SCM Média UH	• Matriz de Coocorrência Estrutural; • Classificador SVM; • 1000 imagens de nódulos: – 500 malignos; – 500 benignos.	LIDC/IDRI	1000	96,70%
Krewer <i>et al.</i> (2013)	• Características de forma e de textura; • 33 casos: – 14 malignos; – 19 benignos.	LIDC/IDRI	33	90,91%
Shen <i>et al.</i> (2017)	• Rede neural convolucional multicortes (MC-CNN); • 1375 casos: – 495 malignos; – 880 benignos.	LIDC/IDRI	1375	87,14%
Shen <i>et al.</i> (2015)	• Rede neural convolucional multiescala (MCNN); • 1375 casos: – 495 malignos; – 880 benignos.	LIDC/IDRI	1375	86,84%
Sergeeva <i>et al.</i> (2016)	• Características morfológicas e de textura; – GLCM; – transformada discreta Wavelet; • 321 nódulos.	LIDC	321	81,3%
Kumar, Wong e Clausi (2015)	• Características profundas (<i>deep features</i>) extraídas de um <i>Autoencoder</i>; • 4.323 nódulos.	LIDC	4323	75,01%

5.2 Classificação de nódulos em níveis de malignância

Esta seção se destina a apresentar e validar os resultados obtidos com o uso do extrator SCM no problema da classificação de nódulos em níveis de malignância. Nesta classificação, considera-se 5 classes, cada uma indicando a probabilidade de malignidade do nódulo.

5.2.1 Configuração ótima para classificação de nódulos

Nesta seção, os resultados obtidos com os classificadores MLP, SVM e K -NN, treinados e testados com as bases de dados geradas a partir do extrator SCM para a classificação dos nódulos em níveis de malignância, são apresentados. De forma semelhante à Seção 5.1.1, o extrator SCM é aplicado com os filtros da Média, Gaussiano, Laplaciano e Sobel. Além disso, o mesmo também é aplicado nas imagens em UH e em tons de cinza.

A Tabela 7 contém os valores médios de ACC, TPR, SPC, PPV e F -Score de 10 iterações para cada classificador junto à SCM com um filtro específico, bem como o tipo de imagem de entrada utilizado. Nessa tabela, os dois melhores resultados foram destacados em verde e em azul, sendo verde a cor utilizada para destacar o melhor.

Tabela 7 – Valores médios de TPR, SPC, PPV, F -Score e ACC para 10 execuções da SCM na classificação multiclasse.

Extrator	Classificador	TPR(%)	SPC(%)	PPV (%)	F -Score(%)	ACC (%)
SCM Média UH	MLP	66,08	38,91	31,72	30,72	55,64
	SVM	79,33	52,78	48,40	49,01	71,00
	KNN	78,76	48,57	47,48	47,57	69,87
SCM Gaussiano UH	MLP	64,93	37,69	31,04	29,45	54,51
	SVM	78,64	55,18	47,40	48,40	70,25
	KNN	79,66	50,38	49,08	49,18	71,08
SCM Laplaciano UH	MLP	65,22	31,73	31,39	30,40	54,01
	SVM	75,56	44,29	43,12	42,72	65,82
	KNN	76,43	44,91	44,52	44,53	66,97
SCM Sobel UH	MLP	68,21	37,73	34,12	31,80	56,74
	SVM	79,54	48,99	48,40	47,94	70,63
	KNN	76,39	46,27	44,40	44,87	67,19
SCM Média Cinza	MLP	57,50	33,56	24,80	20,05	47,30
	SVM	82,35	54,27	52,68	52,66	74,45
	KNN	82,42	53,76	52,80	52,82	74,43
SCM Gaussiano Cinza	MLP	73,30	43,55	39,95	40,58	63,79
	SVM	82,03	54,21	51,76	50,58	73,60
	KNN	82,23	54,78	52,96	53,20	74,36
SCM Laplaciano Cinza	MLP	64,06	31,41	29,48	26,66	52,54
	SVM	75,51	41,41	42,68	41,16	65,30
	KNN	72,17	38,72	39,00	38,69	61,71
SCM Sobel Cinza	MLP	64,03	31,53	30,27	28,32	52,69
	SVM	79,81	49,38	48,28	46,75	70,53
	KNN	79,17	49,03	48,44	48,60	70,46

Com base na Tabela 7, para o problema de classificar os nódulos em um dos cinco níveis de malignância, as configurações de filtro e de tipo de imagem de entrada que obtiveram os melhores resultados foram as que utilizaram o filtro da média e gaussiano em imagens em tons de cinza (SCM Média Cinza e SCM Gaussiano Cinza). A SCM Média Cinza foi a abordagem que apresentou a maior acurácia e maior especificidade quando seus resultados foram utilizados no classificador SVM. Já a SCM Gaussiano Cinza apresentou os maiores valores de TPR, PPV e F -Score quando utilizada junto ao classificador K -NN.

Diferentemente da classificação binária, no problema multiclasse, os valores da medida *F-Score* foram todos abaixo de 50% nas aplicações da SCM em imagens em UH. Nas imagens em tons de cinza, apenas as combinações com filtros da média e gaussiano obtiveram valores de *F-Score* maiores que 50%, exceto quando utilizadas junto ao classificador MLP, que ficaram abaixo desse valor.

As informações dos tempos de treinamento, de teste e de extração média para uma amostra são apresentadas na Tabela 8. Nessa tabela, os dois menores tempos foram destacados em verde e em azul, sendo verde a cor utilizada para destacar o menor. Os tempos de treinamento e de teste, bem como os de extração, são muito semelhantes entre as diferentes configurações. Dessa forma, nenhuma configuração se destaca de forma relevante das demais com relação às medidas de tempo.

Tabela 8 – Tempo médio de treino, teste e extração da SCM e classificadores para a classificação multiclasse.

Extrator	Classificador	Tempo de Treino (s)	Tempo de Teste (s)	Tempo de Extração (s)
SCM Média UH	MLP	7,119540 ± 0,103273	0,000001 ± 0,000001	0,048125 ± 0,006684
	SVM	25,281826 ± 0,067709	0,006391 ± 0,006366	
	K-NN	0,000030 ± 0,000001	0,011761 ± 0,011714	
SCM Gaussiano UH	MLP	7,145532 ± 0,081090	0,000001 ± 0,000001	0,044286 ± 0,005243
	SVM	25,425169 ± 0,122533	0,006283 ± 0,006258	
	K-NN	0,000032 ± 0,000008	0,011733 ± 0,011686	
SCM Laplaciano UH	MLP	7,977795 ± 1,109689	0,000001 ± 0,000001	0,045146 ± 0,005200
	SVM	26,266043 ± 0,148892	0,006566 ± 0,006540	
	K-NN	0,000039 ± 0,000024	0,012832 ± 0,012780	
SCM Sobel UH	MLP	7,158446 ± 0,096704	0,000001 ± 0,000001	0,046031 ± 0,005642
	SVM	25,464731 ± 0,117834	0,006146 ± 0,006122	
	K-NN	0,000029 ± 0,000001	0,011495 ± 0,011449	
SCM Média Cinza	MLP	7,180762 ± 0,084817	0,000001 ± 0,000001	0,047872 ± 0,007061
	SVM	24,295231 ± 0,085797	0,005814 ± 0,005791	
	K-NN	0,000031 ± 0,000004	0,011476 ± 0,011431	
SCM Gaussiano Cinza	MLP	6,728332 ± 1,267050	0,000001 ± 0,000001	0,045036 ± 0,007093
	SVM	24,522326 ± 0,083344	0,006039 ± 0,006014	
	K-NN	0,000029 ± 0,000001	0,011559 ± 0,011513	
SCM Laplaciano Cinza	MLP	7,080100 ± 0,065734	0,000001 ± 0,000001	0,045814 ± 0,007002
	SVM	25,998016 ± 0,084007	0,006545 ± 0,006519	
	K-NN	0,000030 ± 0,000002	0,011703 ± 0,011656	
SCM Sobel Cinza	MLP	6,616489 ± 1,557682	0,000001 ± 0,000001	0,046792 ± 0,007900
	SVM	25,129902 ± 0,048359	0,006191 ± 0,006166	
	K-NN	0,000030 ± 0,000001	0,011334 ± 0,011289	

5.2.2 Comparação com outros extratores de características

O uso da SCM no problema multiclasse é validado através de uma comparação dos resultados desse extrator com os dos métodos GLCM, LBP, MC e ME. Os melhores resultados obtidos com a SCM (SCM Média Cinza e SCM Gaussiano Cinza) foram selecionados para essa comparação.

A Tabela 9 apresenta os resultados médios de ACC, TPR, SPC, PPV e *F-Score* de 10 iterações para cada extrator e classificador, com os dois melhores resultados destacados

em verde e em azul, sendo verde a cor utilizada para destacar o melhor. Com esses resultados, é possível perceber que a SCM, mesmo que com valores não tão altos quanto os alcançados na classificação binária, ainda conquista os melhores valores em todas as medidas.

Em relação ao desempenho dos métodos GLCM, LBP, MC e ME, a maior taxa de *F-Score* obtida por esses foi de 48,59%, através do classificador SVM aplicado aos dados gerados pelo extrator LBP o qual obteve, também, o maior valor de acurácia (70,84%). Porém, por obterem um *F-Score* abaixo de 50% e um alto desbalanceamento entre as medidas SPC e TPR, estes métodos não podem ser considerados eficientes.

Tabela 9 – Valores médios (10 execuções) de TPR, SPC, PPV, *F-Score* e ACC da SCM, GLCM, LBP, MC e ME na classificação multiclasse.

Extrator	Classificador	TPR(%)	SPC(%)	PPV (%)	<i>F-Score</i> (%)	ACC (%)
SCM Média Cinza	MLP	57,50	33,56	24,80	20,05	47,30
	SVM	82,35	54,27	52,68	52,66	74,45
	KNN	82,42	53,76	52,80	52,82	74,43
SCM Gaussiano Cinza	MLP	73,30	43,55	39,95	40,58	63,79
	SVM	82,03	54,21	51,76	50,58	73,60
	KNN	82,23	54,78	52,96	53,20	74,36
GLCM	MLP	58,11	26,13	25,64	24,54	46,69
	SVM	72,12	38,53	38,72	37,52	61,54
	KNN	73,29	39,48	40,24	39,54	62,88
LBP	MLP	57,12	32,86	24,39	20,58	46,92
	SVM	79,56	48,66	48,60	48,59	70,84
	KNN	74,84	44,91	42,36	42,53	65,20
MC	MLP	60,03	28,14	27,05	25,49	48,92
	SVM	74,37	40,05	38,80	34,69	61,81
	KNN	72,81	39,46	39,68	38,94	62,31
ME	MLP	61,57	30,29	28,40	27,29	50,42
	SVM	74,89	41,59	42,00	40,77	64,78
	KNN	77,28	45,28	45,40	44,88	67,83

Os resultados dos tempos médios de treino e teste, bem como os de extração (média para uma amostra), são apresentados na Tabela 10. Nessa tabela, os dois menores tempos foram destacados em verde e em azul, sendo verde a cor utilizada para destacar o menor. Os extratores MC e ME, obtiveram os menores tempos de extração, seguidos pela SCM. Com relação ao tempo de treino e de teste, a SCM alcançou os menores tempos apenas no classificador SVM. Os tempos do classificador *K-NN* foram próximos entre os métodos SCM, MC e ME. Em relação ao classificador MLP, os menores tempos de treinamento foram alcançados com os resultados dos extratores SCM e MC.

Com as informações apresentadas nas Tabelas 9 e 10, conclui-se que o extrator SCM, mesmo não apresentando resultados tão altos quanto na classificação de nódulos em malignos e benignos, ainda se apresenta como a melhor abordagem dentre os métodos analisados no problema de classificação de nódulos em níveis de malignância.

Tabela 10 – Tempo médio de treino, teste e extração da SCM, GLCM, LBP, MC, ME e classificadores na classificação multiclasse.

Extrator	Classificador	Tempo de Treino (s)	Tempo de Teste (s)	Tempo de Extração (s)
SCM Média Cinza	MLP	7,180762 $\pm$ 0,084817	0,000001 $\pm$ 0,000001	0,047872 $\pm$ 0,007061
	SVM	24,295231 $\pm$ 0,085797	0,005814 $\pm$ 0,005791	
	K-NN	0,000031 $\pm$ 0,000004	0,011476 $\pm$ 0,011431	
SCM Gaussiano Cinza	MLP	6,728332 $\pm$ 1,267050	0,000001 $\pm$ 0,000001	0,045036 $\pm$ 0,007093
	SVM	24,522326 $\pm$ 0,083344	0,006039 $\pm$ 0,006014	
	K-NN	0,000029 $\pm$ 0,000001	0,011559 $\pm$ 0,011513	
GLCM	MLP	7,248782 $\pm$ 0,076979	0,000001 $\pm$ 0,000001	6,0137 $\pm$ 0,8831
	SVM	28,660223 $\pm$ 0,061428	0,007197 $\pm$ 0,007168	
	K-NN	0,000034 $\pm$ 0,000002	0,011990 $\pm$ 0,011942	
LBP	MLP	117,122818 $\pm$ 0,297861	0,000001 $\pm$ 0,000001	0,1691 $\pm$ 0,0384
	SVM	164,162704 $\pm$ 0,520061	0,043420 $\pm$ 0,043246	
	K-NN	0,000251 $\pm$ 0,000116	0,047354 $\pm$ 0,047165	
MC	MLP	4,946586 $\pm$ 2,802100	0,000001 $\pm$ 0,000001	0,0053 $\pm$ 0,0026
	SVM	27,855473 $\pm$ 0,067491	0,007331 $\pm$ 0,007301	
	K-NN	0,000033 $\pm$ 0,000011	0,012448 $\pm$ 0,012398	
ME	MLP	7,355840 $\pm$ 0,667804	0,000001 $\pm$ 0,000001	0,0061 $\pm$ 0,0021
	SVM	31,248348 $\pm$ 0,079760	0,007580 $\pm$ 0,007550	
	K-NN	0,000034 $\pm$ 0,000001	0,013036 $\pm$ 0,012984	

5.3 Análise geral dos resultados

Em resumo, este capítulo apresentou os resultados obtidos pelo extrator de características SCM junto aos classificadores MLP, SVM e K-NN na classificação de nódulos em malignos e benignos e em níveis de malignância. Além disso, esse extrator é comparado com os métodos GLCM, LBP, MC e ME.

Na classificação de nódulos em malignos e benignos, a SCM com filtro da Média aplicada em *imagens em UH* e utilizada junto ao classificador SVM foi a abordagem que mais se destacou, alcançando resultados maiores que 95% em todas as medidas utilizadas para as comparações.

Na classificação de nódulos em níveis de malignância, a SCM com filtro da Média e com filtro Gaussiano, ambos aplicados em *imagens em tons de cinza*, foram as abordagens que obtiveram os melhores resultados. A SCM Média Cinza obteve os valores mais altos de acurácia (74,45%) e de especificidade (82,35%). A SCM Gaussiano Cinza obteve os valores mais altos de sensibilidade (54,78%), valor preditivo positivo (52,96%) e F-Score (53,20%).

Em ambas os problemas de classificação, o extrator SCM obteve os melhores resultados quando comparado com os extratores GLCM, LBP, MC e ME. Por mais que no problema da classificação de nódulos em níveis de malignância o valor da medida F-Score não tenha sido tão alto quanto o obtido na classificação binária, este valor ainda foi o maior entre as abordagens comparadas.

Em relação às análises de tempo de extração, os extratores MC e ME alcançaram os menores tempos em ambos os problemas, sempre seguidos pelo extrator SCM. A respeito dos tempos de treinamento e teste, observa-se que os classificadores MLP, SVM e K-NN,

ao serem treinados e testados com as bases geradas pelo extrator SCM, apresentam bons tempos, os quais, quando não são os mais rápidos, ainda se encontram entre esses.

Assim, o uso do extrator SCM no problema da classificação de nódulos em malignos e benignos se apresenta como uma abordagem capaz de obter bons resultados, podendo ser utilizada como uma ferramenta de auxílio ao diagnóstico médico, tornando essa atividade, mais rápida e mais precisa.

6 Conclusão

Esta dissertação tem como principal contribuição apresentar uma nova abordagem para a classificação da malignância de nódulos pulmonares utilizando o extrator de características SCM.

Inicialmente, foram extraídas as regiões de interesse contendo os nódulos pulmonares da base de imagens LIDC/IDRI, com base nas informações fornecidas pela mesma.

Para encontrar a melhor configuração da SCM, a mesma foi aplicada utilizando 4 diferentes filtros (Média, Gaussiano, Laplaciano e Sobel). Além dos filtros, o extrator também foi aplicado nas regiões de interesse em Unidades Hounsfield e em tons de cinza, resultando em 8 configurações diferentes.

A SCM com filtro da Média e aplicada em imagens em Unidades Hounsfield foi selecionada como a melhor configuração para a classificação de nódulos em malignos e benignos, obtendo uma acurácia e um *F-Score* de 96,7%.

Para a classificação em níveis de malignância, duas configurações se destacaram, as quais foram: SCM com filtro da Média e SCM com filtro Gaussiano, ambas aplicadas em imagens em tons de cinza.

Após as melhores configurações terem sido selecionadas, as mesmas foram comparadas com os extratores Matriz de Coocorrência de Níveis de Cinza, Padrões Binários Locais, Momentos Centrais e Momentos Estatístico. Com uma análise dos resultados desses métodos de extração, os quais também foram obtidos com os classificadores MLP, SVM e *K*-NN, concluiu-se que os resultados da SCM foram superiores.

Para melhor validar o uso da SCM na classificação de nódulos, a mesma foi comparada com outros trabalhos propostos para a classificação de nódulos em malignos e benignos e, por sua vez, obteve resultados superiores.

Após a análise dos resultados, conclui-se que a abordagem proposta pode ser utilizada para auxiliar o diagnóstico médico, podendo ser utilizada para acelerar o processo de diagnóstico de malignância de forma precisa e rápida.

6.1 Trabalhos Futuros

Dado o potencial de aplicação da abordagem proposta, pode-se propor os seguintes trabalhos futuros:

- propor uma abordagem para a detecção automática dos nódulos;

- aplicar a abordagem proposta para a classificação de nódulos em outros órgãos;
- aprimorar a abordagem proposta para a obtenção de melhores resultados na classificação em níveis de malignância;
- exibição tridimensional dos nódulos e coloridos de acordo com a malignância, dando início ao desenvolvimento de um sistema CAD.

Referências

ARMATO, S. G. *et al.* The lung image database consortium (lidc) and image database resource initiative (idri): a completed reference database of lung nodules on ct scans. *Medical physics*, Wiley Online Library, v. 38, n. 2, p. 915–931, 2011. Citado 2 vezes nas páginas 43 e 44.

BARROS, A. C. da S. *Optimum Path Snakes: Novo Método de Contornos Ativos Adaptativo e Não-Paramétrico*. Tese (Doutorado) — Universidade de Fortaleza, Ceará, Brasil, 2016. Citado na página 23.

BISHOP, C. M. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006. ISBN 0387310738. Citado na página 37.

CAMARLINGHI, N. Automatic detection of lung nodules in computed tomography images: training and validation of algorithms using public research databases. *The European Physical Journal Plus*, Springer Nature, v. 128, n. 9, sep 2013. Citado na página 23.

CRAMMER, K.; SINGER, Y. On the algorithmic implementation of multiclass kernel-based vector machines. *Journal of machine learning research*, v. 2, n. Dec, p. 265–292, 2001. Citado na página 38.

DUAN, K.; KEERTHI, S. S. Which is the best multiclass svm method? an empirical study. *Multiple classifier systems*, Springer, v. 3541, p. 278–285, 2005. Citado na página 38.

DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern classification*. [S.l.]: John Wiley & Sons, 2012. Citado 2 vezes nas páginas 37 e 41.

FELIX, J.; CORTEZ, P.; HOLANDA, M. A. A new algorithm for automatic segmentation of lung CT images. In: . Campos do Jordão, SP: XI Congresso Brasileiro de informática em Saúde - CBIS, Sociedade brasileira de informática em saúde, 2008. p. 1–6. Citado na página 23.

FLUSSER, J.; ZITOVA, B.; SUK, T. *Moments and moment invariants in pattern recognition*. [S.l.]: John Wiley & Sons, 2009. Citado 2 vezes nas páginas 30 e 31.

GONZALEZ, R. C.; WOODS, R. *Processamento Digital de Imagens. Tradução de Cristina Yamagami e Leonardo Piamonte*. [S.l.]: São Paulo: Pearson Prentice Hall, 2010. Citado 3 vezes nas páginas 23, 31 e 32.

HAN, F. *et al.* A texture feature analysis for diagnosis of pulmonary nodules using lidc-idri database. In: IEEE. *Medical Imaging Physics and Engineering (ICMIPE), 2013 IEEE International Conference on*. [S.l.], 2013. p. 14–18. Citado na página 24.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, Institute of Electrical and Electronics Engineers (IEEE), SMC-3, n. 6, p. 610–621, nov 1973. Disponível em: <<https://doi.org/10.1109%2Ftsmc.1973.4309314>>. Citado 2 vezes nas páginas 27 e 28.

HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. 2nd. ed. EUA: Prentice-Hall, 1999. Citado 4 vezes nas páginas 40, 41, 69 e 70.

HAYKIN, S. S. *Neural networks and Learning Machines*. [S.l.]: Prentice Hall, 2008. v. 3. ISBN 0131471392. Citado na página 46.

HSU, C.-W.; CHANG, C.-C.; LIN, C. A practical guide to support vector classification technical report department of computer science and information engineering. *National Taiwan University, Taipei*, 2003. Citado na página 46.

HU, M.-K. Visual pattern recognition by moment invariants. *IRE transactions on information theory*, Institute of Electrical and Electronics Engineers (IEEE), v. 8, n. 2, p. 179–187, 1962. Citado 3 vezes nas páginas 30, 31 e 32.

KREWER, H. *et al.* Effect of texture features in computer aided diagnosis of pulmonary nodules in low-dose computed tomography. In: IEEE. *Systems, Man, and Cybernetics (SMC), 2013 IEEE International Conference on*. [S.l.], 2013. p. 3887–3891. Citado 2 vezes nas páginas 24 e 55.

KUMAR, D.; WONG, A.; CLAUSI, D. A. Lung nodule classification using deep features in ct images. In: IEEE. *Computer and Robot Vision (CRV), 2015 12th Conference on*. [S.l.], 2015. p. 133–138. Citado 3 vezes nas páginas 24, 25 e 55.

LI, C.; LIU, J.; FOX, M. D. Segmentation of edge preserving gradient vector flow: An approach toward automatically initializing and aplitting of snakes. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2005. Citado na página 23.

MATHWORKS. *Help online for Matlab®*. 2017. Disponível em: <<https://www.mathworks.com/help>>. Citado 2 vezes nas páginas 15 e 28.

OJALA, T.; PIETIKAINEN, M.; HARWOOD, D. Performance evaluation of texture measures with classification based on kullback discrimination of distributions. In: IEEE. *Pattern Recognition, 1994. Vol. 1-Conference A: Computer Vision & Image Processing., Proceedings of the 12th IAPR International Conference on*. [S.l.], 1994. v. 1, p. 582–585. Citado 2 vezes nas páginas 29 e 30.

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*, Institute of Electrical and Electronics Engineers (IEEE), v. 24, n. 7, p. 971–987, jul 2002. Disponível em: <[https://doi.org/10.1109%2Ftpami.2002.1017623](https://doi.org/10.1109/2Ftpami.2002.1017623)>. Citado na página 30.

RAMALHO, G. L. B. *et al.* Rotation-invariant feature extraction using a structural co-occurrence matrix. *Measurement*, v. 94, p. 406 – 415, 2016. ISSN 0263-2241. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0263224116304730>>. Citado 6 vezes nas páginas 15, 24, 32, 33, 34 e 35.

REBOUÇAS FILHO, P. P. *Métodos de contornos ctivos Crisp adaptativo 2D e 3D aplicados na segmentação dos pulmões em imagens de tomografia computadorizada do tórax*. Tese (Doutorado) — Universidade Federal do Ceará, UFC, Departamento de Engenharia de Teleinformática, Fortaleza, Ceará, Brasil, 2013. Citado na página 23.

- ROCHA NETO, A. R. *SINPATCO II: Novas Estratégias de Aprendizado de Máquinas para Classificação de Patologias da Coluna Vertebral*. Tese (Doutorado) — Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, 2011. Citado na página 38.
- ROSEMBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, v. 65, p. 386–408, 1958. Citado na página 69.
- SERGEEVA, M. *et al.* Classification of pulmonary nodules on computed tomography scans. evaluation of the effectiveness of application of textural features extracted using wavelet transform of image. In: IEEE. *Open Innovations Association and Seminar on Information Security and Protection of Information Technology (FRUCT-ISPIT), 2016 18th Conference of*. [S.l.], 2016. p. 291–299. Citado 2 vezes nas páginas 25 e 55.
- SHEN, W. *et al.* Multi-scale convolutional neural networks for lung nodule classification. In: *Lecture Notes in Computer Science*. [S.l.]: Springer International Publishing, 2015. p. 588–599. Citado 2 vezes nas páginas 24 e 55.
- SHEN, W. *et al.* Multi-crop convolutional neural networks for lung nodule malignancy suspiciousness classification. *Pattern Recognition*, Elsevier, v. 61, p. 663–673, 2017. Citado 2 vezes nas páginas 24 e 55.
- SIEGEL, R. L.; MILLER, K. D.; JEMAL, A. Cancer statistics, 2016. *CA: A Cancer Journal for Clinicians*, American Cancer Society, v. 66, n. 1, p. 7–30, jan 2016. Citado na página 23.
- SILVA, A. C. *Algoritmos para Diagnóstico Assistido de Nódulos Pulmonares Solitários em Imagens de Tomografia Computadorizada*. Tese (Doutorado) — Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, Brasil, Fevereiro 2004. Citado na página 23.
- THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern Recognition, Fourth Edition*. 4th. ed. [S.l.]: Academic Press, 2008. ISBN 1597492728, 9781597492720. Citado na página 37.
- VALENTE, I. R. S. *et al.* Automatic 3d pulmonary nodule detection in CT images: A survey. *Computer Methods and Programs in Biomedicine*, Elsevier BV, v. 124, p. 91–107, feb 2016. Citado 2 vezes nas páginas 23 e 24.
- VAPNIK, V. N. *Statistical learning theory*. [S.l.]: Wiley, New York, 1998. v. 1. Citado na página 37.
- WANG, L.; HE, D.-C. Texture classification using texture spectrum. *Pattern Recognition*, Elsevier, v. 23, n. 8, p. 905–910, 1990. Citado na página 29.

Apêndices

APÊNDICE A – *Perceptron* Simples

Das diversas topologias existentes para as redes neurais artificiais, uma bastante popular é a rede *Perceptron* Simples (PS), proposta por ROSEMBLATT (1958). O *Perceptron* é a forma mais simples de uma rede neural, utilizado para a classificação de padrões ditos como linearmente separáveis (padrões que se encontram em lados opostos de um hiperplano) (HAYKIN, 1999).

O *Perceptron* consiste em um conjunto de n entradas (x_i) associadas a n pesos (w_i), uma função de ativação f e uma saída y . Um modelo dessa rede é ilustrado na Figura 11.




Figura 11 – Representação de um *Perceptron* Simples.

A saída do *Perceptron* depende das entradas e de seus pesos associados, sendo calculada por (HAYKIN, 1999)

$$y = f\left(\sum_{i=0}^n x_i w_i\right) \quad (\text{A.1})$$

em que a função de ativação f pode adotar diversas funções, sendo as mais comuns, a função degrau, função pseudolinear, sigmoide e a função gaussiana.

A rede PS possui duas fases distintas: treinamento e teste (ou execução). A etapa de treinamento é supervisionada e consiste em apresentar um conjunto de dados com resposta conhecida e, em seguida, comparar a saída obtida com a saída desejada. Caso algum erro seja detectado, os pesos w_i são atualizados para que se obtenha a saída desejada. O encerramento dessa etapa se dá, geralmente, quando o erro obtido é menor do que um valor de tolerância pré-estabelecido. Ao fim da etapa de treinamento, inicia-se a etapa de teste, na qual, apresenta-se à rede um conjunto de dados cuja saída é desconhecida. Nesta etapa, as amostras fornecidas devem ser corretamente classificadas.

Ressalta-se que a rede *Perceptron* é aplicável somente a problemas linearmente separáveis. Problemas como o da função Ou-exclusivo não podem ser solucionados por esse tipo de rede (HAYKIN, 1999).