

UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE ELETRICIDADE
CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA DE ELETRICIDADE

CLERISTON ARAUJO DA SILVA

**CARACTERIZAÇÃO DE NÓDULOS PULMONARES SOLITÁRIOS
UTILIZANDO ÍNDICE DE SIMPSON E MÁQUINA DE VETORES DE
SUPORTE**

São Luís
2009

CLERISTON ARAUJO DA SILVA

**CARACTERIZAÇÃO DE NÓDULOS PULMONARES SOLITÁRIOS
UTILIZANDO ÍNDICE DE SIMPSON E MÁQUINA DE VETORES DE
SUPORTE**

Dissertação de Mestrado submetida à
Coordenação do Programa de Pós-
Graduação em Engenharia de
Eletricidade da Universidade Federal
do Maranhão como parte dos
requisitos para obtenção do título de
Mestre em Ciência da Computação.

Orientador: Aristófanés Corrêa Silva

Co-orientador: Anselmo Cardoso de
Paiva

São Luís
2009

Silva, Cleriston Araújo da

Caracterização de nódulos pulmonares solitários utilizando Índice de Simpson e Máquina de Vetores de Suporte / Cleriston Araújo da Silva. - São Luís, 2009.

140f.

Orientador: Aristófaes Corrêa Silva.

Co-orientador: Anselmo Cardoso de Paiva.

Impresso por computador (fotocópia).

Dissertação (Mestrado) – Universidade Federal do Maranhão, Programa de Pós-Graduação em Engenharia de Eletricidade. São Luís, 2009.

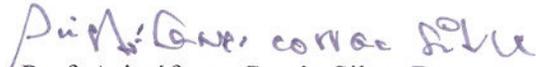
1. Nódulo pulmonar. 2. Tomografia computadorizada. 3. Índice Simpson. I. Silva, Aristófaes Corrêa, orient. II. Paiva, Anselmo Cardoso de., co-orient. III. Título.

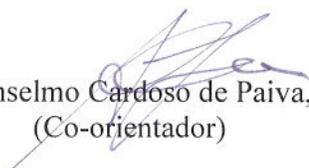
CDU 616.24:616-073

**CARACTERIZAÇÃO DE NÓDULOS PULMONARES
SOLITÁRIOS UTILIZANDO ÍNDICE DE SIMPSON
E MÁQUINA DE VETORES DE SUPORTE**

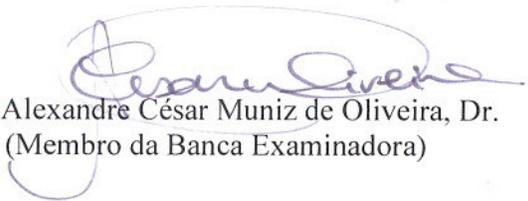
Cleriston Araújo da Silva

Dissertação aprovada em 12 de fevereiro de 2009.


Prof. Aristófares Corrêa Silva, Dr.
(Orientador)


Prof. Anselmo Cardoso de Paiva, Dr.
(Co-orientador)


Prof. Paulo Cezar Pinto Carvalho, Dr.
(Membro da Banca Examinadora)


Prof. Alexandre César Muniz de Oliveira, Dr.
(Membro da Banca Examinadora)

À minha família.

AGRADECIMENTOS

À Deus, sobre todas as outras coisas, pelo eterno amor e paixão a todos nós e por ter permitido a mim a possibilidade de concluir mais uma etapa na minha vida.

Ao meu orientador, Ari, primeiramente, pela credibilidade a mim concedida, seguida paciência, atenção e conselhos que contribuíram significativamente em meu aprendizado e crescimento pessoal.

Ao meu co-orientador, Anselmo, pela disponibilidade e clareza nos momentos de discussões.

Aos meus pais, Alves, Djanira, Maria do Socorro, pela dedicação e apoio em todos esses anos.

À minha família, alicerce fundamental que manteve em mim a base necessária para dar continuidade aos trabalhos.

Às minhas amigas, Eva e Jeane, pelo incentivo e a Eveline por tudo.

À Ednéa, pelo companheirismo, carinho, incentivo e compreensão.

Aos colegas de laboratório, pelo prazer da companhia, pelas trocas de idéias. Em particular ao grande Stelmo, por compartilhar de seu conhecimento de causa no assunto e me ajudar na evolução deste trabalho.

Aos colegas de mestrado pela graça de conhecê-los e poder partilhar de alegrias e tristezas durante essa caminhada.

Aos colegas de serviço, aqueles ajudaram e atrapalharam de alguma forma, toda lição foi bem vinda. Um agradecimento particular a Admarly e Eurides, pela amizade sincera.

À equipe dos “cinco” da paróquia do Maiobão. Muitas vitórias e derrotas compartilhadas nesse último ano.

Aos professores Alexandre César e Paulo Cezar, pelo aceite e disponibilidade para compor a banca examinadora.

Aos muitos outros amigos não citados, porém não esquecidos que fizeram e fazem de mim uma pessoa feliz e crente na importância da convivência harmoniosa.

RESUMO

O diagnóstico de nódulos pulmonares tem sido buscado constantemente por pesquisadores como forma de amenizar os altos índices de mortalidade mundial relacionado ao câncer de pulmão. O uso de imagens médicas, como a Tomografia Computadorizada, tem possibilitado um aprofundamento e melhoramento de técnicas para avaliar exames e prover diagnósticos. Este trabalho apresenta uma metodologia para diagnóstico de nódulos pulmonares solitários que possa servir como um auxílio para estudos realizados em áreas afins e para especialistas. Esta metodologia foi aplicada a duas diferentes bases de dados de imagens. A representação dos nódulos foi feita com a extração de medidas de geometria e de textura sendo esta última descrita através do Índice de Simpson, uma estatística utilizada na Análise Espacial e na Ecologia. Essas medidas foram submetidas ao classificador Máquina de Vetores de Suporte - MVS em duas abordagens: a abordagem tradicional e abordagem usando uma classe. Com abordagem MVS tradicional, obtiveram-se taxas de sensibilidade de 90%, especificidade de 96,67% e acurácia de 95%. Usando MVS de uma classe, as taxas obtidas foram: sensibilidade igual a 89,7%, especificidade igual a 89,7% e acurácia igual a 89,7%.

Palavras-chave: Imagens Médicas, Diagnóstico de Nódulo Pulmonar, Índice de Simpson, Máquina de Vetores de Suporte, Tomografia Computadorizada.

ABSTRACT

The diagnosis of lung nodules has been constantly looked for by researchers as a way to minimize the high global mortality indices related to lung cancer. The usage of medical images, such as Computerized Tomography, has made possible the deepening and the improvement of techniques used to evaluate exams and provide diagnosis. This work presents a methodology for diagnosing single lung nodules that can be an aid for studies performed on similar areas and for specialists. This methodology was applied to two different image databases. The representation of the nodules was done with extraction of geometry and texture features, being the last one described through Simpson's Index, a statistic used in Spatial Analysis and in Ecology. These features were submitted to the Support Vector Machine classifier (SVM) in two approaches: the traditional approach and the approach by using One Class. With the traditional SVM approach, we have obtained sensibility rates of 90%, specificity of 96.67% and accuracy of 95%. Using One Class SVM, the obtained rates were: sensibility of 89.7%, specificity of 89.7% and accuracy of 89.7%.

Keywords: Medical images, Lung nodule diagnosis, Simpson's Index, Support Vector Machine, Computerized Tomography.

LISTA DE TABELAS

Tabela 1 –	Conjunto de treinamento e teste na etapa de classificação.	75
Tabela 2 –	Resultados dos testes usando geometria extraída da Base I e classificada pela MVS tradicional.	79
Tabela 3 –	Resultados dos testes usando geometria extraída da Base II e classificada pela MVS tradicional.	79
Tabela 4 –	Resultados dos testes usando geometria extraída da Base I e classificada pela MVS de uma classe.	80
Tabela 5 –	Resultados dos testes usando geometria extraída da Base II e classificada pela MVS de uma classe.	80
Tabela 6 –	Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 30/70.	82
Tabela 7 –	Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 40/60.	83
Tabela 8 –	Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificada pela MVS tradicional com configuração 50/50.	84
Tabela 9 –	Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 60/40.	85
Tabela 10 –	Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 70/30.	86
Tabela 11 –	Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 80/20.	86

Tabela 12 – Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 30/70.	88
Tabela 13 – Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 40/60.	89
Tabela 14 – Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 50/50.	89
Tabela 15 – Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 60/40.	90
Tabela 16 – Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 70/30.	91
Tabela 17 – Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 80/20.	91
Tabela 18 – Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 30/70.	92
Tabela 19 – Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 40/60.	93
Tabela 20 – Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 50/50.	94
Tabela 21 – Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 60/40.	95

Tabela 22 – Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 70/30.	96
Tabela 23 – Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 80/20.	97
Tabela 24 – Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 30/70.	98
Tabela 25 – Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 40/60.	99
Tabela 26 – Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 50/50.	99
Tabela 27 – Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 60/40.	100
Tabela 28 – Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 70/30.	101
Tabela 29 – Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 80/20.	102
Tabela 30 – Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 30/70.	104
Tabela 31 – Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 40/60.	104

Tabela 32 – Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 50/50.	105
Tabela 33 – Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 60/40.	106
Tabela 34 – Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 70/30.	106
Tabela 35 – Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 80/20.	107
Tabela 36 – Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 30/70.	108
Tabela 37 – Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 40/60.	109
Tabela 38 – Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 50/50.	110
Tabela 39 – Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 60/40.	111
Tabela 40 – Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 70/30.	112

Tabela 41 – Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 80/20.	112
Tabela 42 – Resultados dos testes usando textura extraída em esferas e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 30/70.	114
Tabela 43 – Resultados dos testes usando textura extraída em esferas e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 40/60.	114
Tabela 44 – Resultados dos testes usando textura extraída em esferas e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 50/50.	115
Tabela 45 – Resultados dos testes usando textura extraída em esferas e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 60/40.	116
Tabela 46 – Resultados dos testes usando textura extraída em esferas e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 70/30.	117
Tabela 47 – Resultados dos testes usando textura extraída em esferas e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 80/20.	117
Tabela 48 – Resultados dos testes usando textura extraída em esferas e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 30/70.	119
Tabela 49 – Resultados dos testes usando textura extraída em esferas e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 40/60.	120
Tabela 50 – Resultados dos testes usando textura extraída em esferas e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 50/50.	121

Tabela 51 – Resultados dos testes usando textura extraída em esferas e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 60/40.	122
Tabela 52 – Resultados dos testes usando textura extraída em esferas e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 70/30.	122
Tabela 53 – Resultados dos testes usando textura extraída em esferas e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 80/20.	123
Tabela 54 – Síntese de resultados obtidos na metodologia.	127

LISTA DE FIGURAS

Figura 1 - Causas do aparecimento do NPS	28
Figura 2 - Exemplos de nódulos pulmonares	29
Figura 3 - Estrutura pulmonar identificada em uma Tomografia Computadorizada da Caixa Torácica	30
Figura 4 - Partes de um tomógrafo computadorizado	33
Figura 5 - Fluxo de funcionamento de um <i>software</i> CADx típico	36
Figura 6 - Passos fundamentais em processamento de imagens digitais	40
Figura 7 - Histograma com bimodalidade baixa e bimodalidade alta	44
Figura 8 - Crescimento por região a partir de uma semente	46
Figura 9 - Crescimento de região 3D estabelecido nas diversas fatias	46
Figura 10 - Ilustração da densidade esférica de três objetos em duas dimensões	52
Figura 11 - Separação de duas classes através de hiperplanos	56
Figura 12 - Vetores de suporte (destacados por círculos)	59
Figura 13 - Passos da Metodologia	65
Figura 14 - Segmentação de nódulo utilizando o <i>software</i> <i>Bebúi</i>	69
Figura 15 - Nódulo segmentado da base LIDC	70
Figura 16 – Representação em 2D da Análise em Esferas Concêntricas contendo 6 raios aplicada ao nódulo	72
Figura 17 - Representação em 2D da Análise em Anéis Esféricos contendo 6 raios externos aplicada ao nódulo	73

LISTA DE SIGLAS

- ACR** - *American College of Radiology* (Colégio Americano de Radiologia)
- CAD** – *Computer-aided Detection* (Detecção Auxiliada por Computador)
- CADx** – *Computer-aided Diagnosis* (Diagnóstico Auxiliado por Computador)
- DICOM** – *Digital Imaging Communications in Medicine* (Representação Digital para Comunicação em Medicina)
- FN** - Falso Negativo
- FOV** - *Field Of View* (Campo de Visão)
- FP** - Falso Positivo
- HU** - *Hounsfield Unit*
- IO** – *Information Object* (Objeto de Informação)
- INCA** - Instituto Nacional de Câncer
- LDCT** - *Low-dose computer tomography* (Tomografia Computadorizada de baixa dosagem)
- LIDC** - *Lung Image Database Consortium* (Consórcio de Banco de Dados de Imagem de Pulmão)
- NCI** - *National Cancer Institute* (Instituto Nacional do Câncer – EUA)
- NCIA** - *National Cancer Imaging Archive* (Arquivo Nacional de Imagens de Câncer)
- NEMA** – *National Electrical Manufacturers Association* (Associação Nacional de Fabricantes de Equipamentos Elétricos – EUA)
- NPS** - Nódulo Pulmonar Solitário
- PACS** - *Picture Archiving and Communications Systems* (Sistemas de Comunicação e Armazenamento de Imagens)
- MVS** – *Máquina de Vetores de Suporte*
- TC** – Tomografia Computadorizada
- VP** - Verdadeiro Positivo
- VN** - Verdadeiro Negativo
- VPP** - Valor Preditivo Positivo
- VPN** - Valor Preditivo Negativo
- XML** - *eXtensible Markup Language*

SUMÁRIO

1	INTRODUÇÃO	18
1.1	Objetivos	20
1.2	Contribuições	21
1.3	Trabalhos Relacionados	22
1.4	Estrutura da Dissertação	25
2	FUNDAMENTAÇÃO TEÓRICA	27
2.1	Nódulo Pulmonar Solitário	27
2.2	Tomografia Computadoriza	32
2.2.1	Imagens DICOM	34
2.3	Sistema de Auxílio à Detecção e Diagnóstico	35
2.4	Processamento de Imagens Digitais	38
2.5	Segmentação	42
2.5.1	Limiarização ou <i>Thresholding</i>	43
2.5.1.1	Método de Otsu	43
2.5.2	Crescimento de regiões 3D	45
2.6	Representação e Descrição	46
2.6.1	Análise de Textura	47
2.6.1.1	Índice de Simpson	48
2.6.2	Análise de Geometria	50
2.6.2.1	Desproporção Esférica	51
2.6.2.2	Densidade Esférica	52
2.6.2.3	Esfericidade	53
2.7	Reconhecimento de Padrões	53
2.7.1	Classificadores	55
2.7.1.1	Máquina de Vetores de Suporte	55
2.7.1.1.1	MVS Tradicional	57
2.7.1.1.2	MVS de uma classe	60
2.8	Avaliação dos Resultados	62

3	METODOLOGIA	65
3.1	Aquisição das Imagens	66
3.1.1	Base I.....	66
3.1.2	Base II.....	67
3.2	Segmentação 3D dos Nódulos	68
3.2.1	Segmentação da Base I.....	68
3.2.2	Segmentação da Base II.....	69
3.3	Extração de Característica	70
3.3.1	Característica de Textura.....	70
3.3.2	Característica de Geometria	73
3.3.3	Característica de Textura e Geometria	73
3.4	Classificação	74
3.4	Software e Hardware utilizados	75
4	TESTES E RESULTADOS	77
4.1	Testes usando Geometria	78
4.2	Testes usando Textura	81
4.2.1	Análise em Anéis	81
4.2.2	Análise em Esferas	92
4.3	Testes usando Textura e Geometria	102
4.3.1	Textura em Anéis e Geometria	103
4.3.2	Textura em Esferas e Geometria	113
4.4	Avaliação Final	124
5	CONCLUSÃO	129
	REFERÊNCIAS	131

1 INTRODUÇÃO

O câncer de pulmão é um dos mais sérios problemas de saúde pública na Europa, nos Estados Unidos e em muitas outras regiões do mundo, especialmente pelo fato de estar se tornando líder de mortalidade, em termos de câncer, tanto para homens quanto para mulheres. As estatísticas do NCI – National Cancer Institute (NCI, 2008) estimaram 215.020 novos casos e 161.840 mortes nos Estados Unidos em 2008. No Brasil, o câncer de pulmão ocupa o primeiro lugar em morte por câncer entre os homens e o segundo entre as mulheres, perdendo apenas para o câncer de mama. Estimou-se que, em 2008, segundo o Instituto Nacional do Câncer (INCA, 2008), a neoplasia pulmonar causou 27.270 mortes (17.810 homens e 9.460 mulheres). Estes valores correspondem a um risco estimado de 19 casos novos a cada 100 mil homens e 10 para cada 100 mil mulheres.

O hábito de consumo de tabaco é o mais importante fator de risco para o desenvolvimento do câncer de pulmão. Comparados com os não fumantes, os tabagistas têm cerca de 20 a 30 vezes mais risco de desenvolver câncer de pulmão. Em geral, as taxas de incidência em um determinado país refletem seu consumo de cigarros (INCA, 2008).

Esta doença é um dos grandes problemas existentes da atualidade no que diz respeito à saúde humana. Diversas pesquisas vêm sendo desenvolvidas para a melhor compreensão da mesma, no intuito de compreender suas origens, detectá-la em fases iniciais, desenvolver métodos para diagnosticá-las e propor formas de tratamento eficientes sem maiores conseqüências para o paciente. Estudos indicam que a sobrevivência dos pacientes diagnosticados, após 5 anos, varia entre 13% e 21% (INCA, 2008) e que a identificação da enfermidade ainda em suas etapas iniciais pode elevar a chance de sobrevivência do paciente para até 70% (NAVARRO, 2003). Sendo assim, o diagnóstico precoce é o melhor meio de garantir o sucesso do tratamento.

Do ponto de vista biológico, o câncer de pulmão é um crescimento descontrolado de células anormais em um ou ambos os pulmões, que podem

se reproduzir rapidamente e originar metástases¹ mesmo se o paciente for assintomático. As expansões de células de câncer danificam a função dos pulmões se obstruírem os brônquios, mas não se estiverem localizadas em outras regiões do órgão. O parênquima pulmonar não tem terminações nervosas, por isso, a menos que o tumor invada precocemente a pleura parietal, a dor será um sinal atrasado da presença do câncer (OST; FEIN; FEINSILVER, 2003).

Uma das melhores chances de se curar o câncer de pulmão é quando em um paciente assintomático, normalmente um fumante, é incidentalmente encontrado um nódulo pulmonar num exame de Raio-X ou Tomografia Computadorizada (TC) (SILVA, 2007).

Vários equipamentos de alta tecnologia foram desenvolvidos para auxiliar os especialistas a obterem dados que os conduzam a um diagnóstico precoce. Dentre eles, a TC helicoidal vem se destacando, pois além de revelar o câncer pulmonar em um estágio precoce, muitas vezes imperceptíveis a radiografia de tórax convencional, permite uma reconstrução tridimensional da imagem (SILVA, 2007).

O problema é que um único exame de TC costuma ser composto por dezenas de imagens e sua observação cuidadosa leva tempo e requer muita paciência e atenção o que pode levar o especialista a uma fadiga e conseqüentemente ao comprometimento do diagnóstico.

Estudos anteriores relatam que radiologistas, algumas vezes, não notam a existência de algum nódulo enquanto analisam um exame de TC, devido ao grande número de imagens, podendo chegar a 300, a serem analisadas para uma TC (SWENSEN et al., 2002; PELDSCHUS et al., 2005). Além disso, o desempenho do radiologista pode ser influenciado por problemas pessoais, fadiga e sua experiência na área.

Utilizando as informações obtidas a partir das imagens médicas, sistemas assistidos por computador vêm sendo desenvolvidos com a finalidade de auxílio no diagnóstico de nódulos desde a sua detecção até uma possível classificação de sua natureza (benigna ou maligna, por exemplo), fornecendo

¹ Metástase é a formação de uma nova lesão tumoral a partir da primeira, mas sem continuidade entre as duas.

assim, uma segunda opinião ao radiologista e demais especialistas sobre a análise dos exames.

Estes sistemas podem ser do tipo CAD (*Computer-Aided Detection* – Detecção assistida por computador) ou CADx (*Computer-Aided Diagnosis* – Diagnóstico assistido por computador). Sistemas CAD são sistemas que auxiliam a detecção de anormalidades, entretanto, não realizam qualquer tipo de diagnóstico sobre as mesmas. Estes sistemas auxiliam o médico na identificação de regiões de interesse no exame. Os sistemas CADx classificam estruturas segmentadas sugerindo que a natureza da lesão, na maioria das aplicações, seja identificada como benigna ou maligna para o caso de nódulos pulmonares.

O médico usa os resultados da análise computadorizada como uma segunda opinião na detecção e diagnóstico de nódulos. A decisão final é determinada pelo especialista (WHITE et al., 2008).

Tipicamente, esses sistemas utilizam variadas técnicas de processamento de imagens que incluem técnicas de extração de características baseadas em estatística, morfologia matemática, descrição em conjunto e ainda técnicas de reconhecimento de padrão para a tarefa de classificação.

1.1 Objetivos

Os métodos utilizados pelos especialistas para o diagnóstico do câncer de pulmão consistem basicamente em análise visual do filme impresso da TC do tórax do paciente. Tal análise consiste basicamente na observação de características como localização, diâmetro, geometria e presença de calcificação que podem fornecer informações que permitam distinguir os nódulos pulmonares entre benignos ou malignos.

Sendo assim, a extração cirúrgica do nódulo é a conduta tomada na maioria dos pacientes com nódulo pulmonar indeterminado. Contudo, muitas dessas intervenções poderiam ser evitadas, visto que, com frequência, tratam-se de nódulos benignos, principalmente no Brasil e em outros países em desenvolvimento, onde a incidência de tuberculose é elevada (INCA, 2008).

Portanto, é fundamental o uso de técnicas mais precisas para melhor avaliar a massa nodular e suas características, podendo dessa forma determinar com mais credibilidade a benignidade ou a malignidade do nódulo, e até mesmo a sua atividade biológica, informação potencialmente útil nos casos em que o nódulo é um câncer.

Com isso, o principal objetivo deste trabalho é apresentar uma metodologia para a classificação de nódulos pulmonares extraídas de imagens de TC utilizando medidas de análise estatística de biodiversidade para descrição de textura: Índice de Simpson. Essa medida será avaliada pela técnica de classificação Máquina de Vetores de Suporte (VAPNICK, 1995), usando duas abordagens diferentes a fim de descobrir qual delas apresenta melhor desempenho na metodologia uma vez que as técnicas MVS vêm sendo bastante utilizada na tarefa de reconhecimento de padrões.

Além disso, a qualidade dos resultados obtidos a partir deste trabalho poderá tornar possível a incorporação do presente método em uma ferramenta para a área médica, que possa servir como uma segunda opinião para o especialista durante a etapa de diagnóstico assistido por computador, especialmente no caso de lesões ainda em estágio inicial, quando a identificação do nódulo tem um impacto mais decisivo no tratamento, é possível que, devido ao seu tamanho reduzido, ele não seja prontamente identificado visualmente.

1.2 Contribuições

Este trabalho vem contribuir com o desenvolvimento de uma metodologia de diagnóstico de nódulo pulmonar utilizando uma medida de biodiversidade, o Índice de Simpson, como medida representativa de textura a ser analisada como boa característica na tarefa de classificação. Conforme dito anteriormente, na classificação usaremos a técnica de Máquina de Vetores de Suporte onde procura-se avaliar os resultados a partir do uso de duas formas dessa técnica: Máquina de Vetores de Suporte tradicional e Máquina de Vetores de Suporte de uma classe.

Tal metodologia pode ser de grande utilidade para os especialistas durante a análise dos nódulos para conseqüente diagnóstico, especialmente em casos onde a interpretação radiológica é indeterminada – caso no qual, normalmente, como já dito anteriormente, a conduta adotada para a maioria dos pacientes é a extração cirúrgica. Com a confirmação da benignidade pela análise usando a metodologia proposta, muitas intervenções cirúrgicas desnecessárias poderão vir a ser evitadas; bem como, a precoce confirmação de malignidade pode evitar os transtornos e riscos da espera da evolução do quadro clínico para uma definitiva tomada de decisão.

Todavia, é importante ressaltar que não se pretende substituir o papel do médico especialista, e sim disponibilizar a esses profissionais de saúde uma ferramenta que venha auxiliar no diagnóstico da doença em questão. Este auxílio se dá através de uma segunda opinião que possa vir a confirmar ou questionar a análise prévia feita pelo profissional médico especializado.

Pretende-se, ainda, contribuir com uma metodologia eficaz para a predição de nódulos pulmonares, mediante ao complexo problema de diagnóstico assistido por computador, de forma a incentivar futuros estudos e aprofundamentos para a questão do câncer pulmonar.

1.3 Trabalhos relacionados

Pesquisas têm sido feitas no campo da computação com o intuito de produzir ferramentas que auxiliem o trabalho do médico na análise de imagens de TC. (PELDSCHUS et al., 2005) demonstrou em seu trabalho a importância de ferramentas CAD como uma segunda opinião no diagnóstico de nódulos pulmonares. Em seu trabalho, demonstrou que cerca de 33% dos diagnósticos negativos que faziam parte de sua base de dados tornaram-se positivos após o auxílio computacional.

No trabalho de Armato et al.(2002) é relatada a performance de um sistema CAD usando uma base de dados de 38 imagens de TC de baixa dosagem (LDCT - *Low-dose computer tomography*) que faz a varredura da imagem e detecta os nódulos de câncer de pulmão. Este sistema detectou

corretamente 84% dos casos de câncer com taxa média de 1,0 falso-positivo por exame.

Algumas pesquisas têm demonstrado metodologias e algoritmos para a detecção automática ou semi-automática de nódulos pulmonares solitários. Algumas metodologias propostas são adotadas técnicas simples como limiares de intensidade de cinza, a exemplo de Zhao et al. (2003, 2004). Nesses trabalhos, a detecção de pequenos nódulos se deu através de máximos locais de intensidade de cinza com posterior redução de falsos positivos baseada em características geométricas.

Outros trabalhos relatam um ganho na tarefa de diagnóstico quando a análise é associada ao recurso do contraste iodado. Swensen (1995) propôs determinar a malignidade de nódulos pulmonares solitários através da análise de injeção de contraste iodado em imagens de tomografia computadorizada verificando a ocorrência de uma alteração nos valores de atenuação dos nódulos (HU - *Hounsfield Unit* ou Unidade de Hounsfield). O autor conseguiu estabelecer que nódulos malignos apresentam uma grande mudança nesta densidade a partir da impregnação do contraste, possibilitando assim representar um padrão para nódulos benignos e malignos. Verificou ainda que a vascularidade dos nódulos pulmonares solitários malignos é um bom fator de discriminação, uma vez que uma grande existência de vasos sanguíneos ajuda no realce do nódulo maligno. Swensen, (2000) propôs a avaliação de benignidade de nódulos pulmonares em exames de CT, com o uso de contraste iodado, através de medida estatística do valor de HU onde se verificou que para o limiar de HU igual a 15, obteve-se uma sensibilidade de 98%, especificidade de 58% e acurácia de 77% e constatou-se que nódulos pulmonares com valor de $HU \leq 15$, são fortemente indicados como benignos.

No trabalho de Shah et al. (2005) é investigada a utilização de um sistema CADx na tarefa de diferenciar entre nódulos malignos e nódulos benignos usando dados volumétricos dos nódulos adquiridos antes e depois da injeção de contraste. Neste trabalho os nódulos foram classificados usando regressão logística e análise discriminante quadrática, com resultados baseados na curva ROC de 0,92 e 0,69, respectivamente.

Trabalhos existentes na literatura médica evidenciam a possibilidade de detecção e diagnóstico através do estudo da morfologia dos nódulos em

exames de TC. Em El-baz et al. (2007), recentemente foi proposto um diagnóstico de nódulos pulmonares pela avaliação da taxa de crescimento dos nódulos num determinado período usando o registro 3D do volume para quantificá-lo, Neste trabalho foi obtida uma acurácia de 100% num intervalo de confiança de 95%.

Em Souza et al. (2008) é avaliado um conjunto de três medidas geométricas como forma de discriminação entre nódulos e não nódulos usando Máquinas de Vetores de Suporte como classificador, nos teste foram obtidos 100% de correta classificação.

A análise de textura tem sido aplicada como técnica quantitativa para prover informações diferenciais entre nódulos pulmonares solitários. Como exemplo, Silva (2004) apresenta a possibilidade de representação de medidas de textura combinadas com medidas de geometria para discriminar nódulos pulmonares com o uso de funções geoestatísticas como semivariograma, covariograma, correlograma e semimadograma, obtendo resultados de 80% na acurácia.

Ainda para a obtenção de características de texturas através de funções geoestatísticas temos os trabalhos apresentados em Silva et al. (2007) e Silva et al. (2008). Em Silva et al. (2007) foram investigadas outras funções geoestatísticas como Índice de Moran, Coeficiente de Geary as quais obtiveram bons resultados para acurácia, acima de 90%, com sensibilidade de 96,55%. Silva et al. (2008), apresentou uma nova medida de textura extraída a partir do uso de funções geoestatísticas, como a função K de Ripley resultando em acurácia de 97,4% e sensibilidade de 90%.

Liang et al. (2006) propõe um sistema CADx através do uso de Redes Neurais o qual usa técnicas de registro de imagens para extrair as regiões de interesse e em seguida obter medidas de texturas, considerando o método de dependência espacial dos níveis de cinza, para treinar e testar a Rede Neural. Para 20 imagens de TC de 20 pacientes analisados, os resultados obtidos foram de 100% de acurácia para os 15 conjuntos de treinamento e 100% para os 5 conjunto de teste.

Petkovska et al. (2006) mostra uma abordagem que combina o registro de imagens e a extração de medidas de texturas em imagens de CT com contraste iodado. Neste trabalho é proposta a utilização de um mapa de

contraste para identificar os valores de atenuações de maiores ocorrências (médios) e exibi-los em imagens para melhor representação e comparação de resultados. O trabalho sugere ainda uma análise de medidas de textura obtidas a partir do cálculo da matriz de co-ocorrência para avaliar a natureza dos nódulos e determinar padrões para estes. Com o limiar de 15 HU, 93% dos nódulos malignos e 79% dos nódulos benignos apresentaram melhoramento visual.

Em grande parte dos trabalhos, após ter conseguido extrair características representativas dos nódulos, são utilizados classificadores para identificá-las no grupo de nódulos ou não-nódulos. Um dos classificadores que tem se tornado muito popular pela grande capacidade de generalização são as Máquinas de Vetores de Suporte, que foi utilizada em diversas pesquisas (LU et al., 2004; MOUSA et al., 2002; SOUZA et al., 2008). Pode-se citar ainda a contribuição de Suykens (1999) que desenvolveu uma técnica derivada das Máquinas de Vetores de Suporte com o objetivo de reduzir o tempo de processamento computacional através do uso de sistema lineares para obtenção das classificações e ainda pela redução da função de custo pelo método de mínimos quadrados (SUYKENS et al., 2001 e CARVALHO, 2005). As redes neurais e os algoritmos de agrupamento constituem outras classes de classificadores muito comuns e também apresentam resultados satisfatórios (SILVA et al., 2004), (LO et al., 2003).

1.4 Estrutura da Dissertação

Este trabalho é organizado de forma a apresentar conceitos tanto da área médica quanto da área de processamento de imagens, devido ao seu caráter multidisciplinar, a fim de possibilitar o conhecimento suficiente para a compreensão do problema abordado. Assim, O restante desse trabalho, além da presente Introdução, está organizado em mais quatro capítulos descritos resumidamente a seguir.

No Capítulo 2, apresentam-se, brevemente, algumas propriedades da fisiologia pulmonar e do próprio nódulo pulmonar, a fim de proporcionar uma base de entendimento a respeito da área de aplicação da pesquisa

desenvolvida. Apresenta-se, ainda, a fundamentação teórica a respeito da área de processamento digital de imagens que foram necessárias no trabalho. Abordamos em seguida, a extração de textura através da função estatística de biodiversidade (Índice de Simpson) e a técnica de classificação denominada Máquinas de Vetores de Suporte.

O Capítulo 3 descreve a metodologia utilizada para realizar a classificação de nódulos pulmonares, extraídos de exames de tomografias computadorizadas, em benigno e maligno, utilizando a extração de textura baseada em estatística de biodiversidade e Máquinas de Vetores de Suporte.

No Capítulo 4, são apresentados e discutidos os resultados obtidos através da metodologia proposta.

O Capítulo 5 apresenta as considerações finais sobre o trabalho, mostrando a eficiência dos métodos utilizados e apresentando sugestões para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta a fundamentação teórica utilizada no desenvolvimento deste trabalho e necessária para compreensão dos métodos utilizados para alcançar os objetivos esperados pelo mesmo. Aborda-se o nódulo pulmonar solitário, o método de aquisição de imagens por tomografia computadorizada, o padrão de imagens DICOM, teoria sobre processamento de imagens, métodos de análise de textura baseado em estatística de biodiversidade, com o uso do Índice de Simpson, método de classificação e reconhecimento de padrão utilizando Máquina de Vetores de Suporte e técnicas de validação de resultados.

2.1 Nódulo Pulmonar Solitário

O Nódulo Pulmonar Solitário (NPS) é uma aglomeração de células que difere em densidade e textura do tecido circundante. Podem ter formato esférico ou irregular e apresentar comportamento benigno ou maligno. É uma lesão única, menor que 3 cm. Os nódulos malignos são denominados de câncer, que é um crescimento anormal de células com a propriedade de invadir tanto os tecidos adjacentes quanto os distantes. Os nódulos benignos, apesar de não provocarem metástase, ainda podem interferir no funcionamento do órgão no qual estão alojados.

Boa parte dos nódulos pulmonares surge nas paredes dos brônquios, o que dá ao câncer pulmonar também o nome de broncogênico. Eles também podem ocorrer com frequência nas paredes dos pulmões e podem levar vários anos para se desenvolverem.

A fase inicial de desenvolvimento é assintomática sendo formada por uma área pré-cancerosa não identificável por exames de imagem. Com o passar do tempo, entretanto, ocorre o desenvolvimento do nódulo e, possivelmente, o espalhamento de suas células alteradas pela corrente sanguínea, configurando uma metástase (NCI, 2008).

Um nódulo pulmonar solitário pode ser considerado benigno caso seu crescimento permaneça estagnado por um período de dois anos. As lesões malignas, ao contrário, apresentam tempo de duplicação que pode variar entre 30 e 400 dias, ou seja, seu volume, geralmente, torna-se duas vezes maior nesse intervalo de tempo (UEHARA et al., 1998).

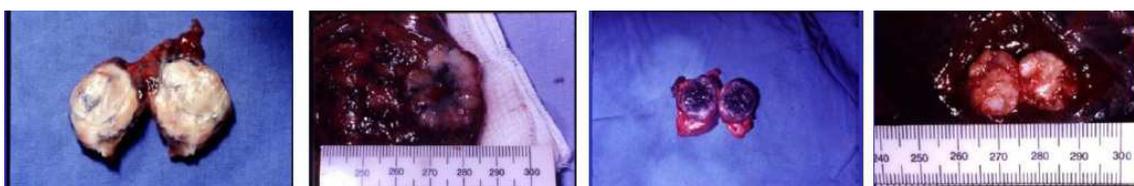
Podem-se citar algumas causas do seu aparecimento (SZARF; SOUZA, 2009) os quais são ilustrados nas fotos da Figura 1. São estas:

a) Causas não-neoplásicas

- Granulomas por infecção ou ferimento (tuberculose e histoplasmose) ou não infecciosos (sarcoidose, granulomatose de Wegener);
- Hamartomas²;
- Doenças parasitárias, más formações arteriovenosas entre outras;

b) Causas neoplásicas

- Tumores broncogênicos como o carcinoma e linfoma primário de pulmão;
- Tumores metastáticos como o sarcoma de Kaposi e adenocarcinomas de qualquer origem;



(a)

(b)

(c)

(d)

Figura 1 - Causas do aparecimento do NPS.

(a) Granulomas; (b) Carcinomas primários; (c) Metástase; (d) Harmartomas

Fonte: Silva (2004).

Sob o ponto de vista radiológico, nódulo pulmonar solitário é definido como uma estrutura aproximadamente esférica de 3 mm a 3 cm de diâmetros que podem ser de natureza benigna ou maligna (TARANTINO, 1997). A Figura 2 mostra exemplos (de uma fatia de um exame de TC) de nódulos pulmonares.

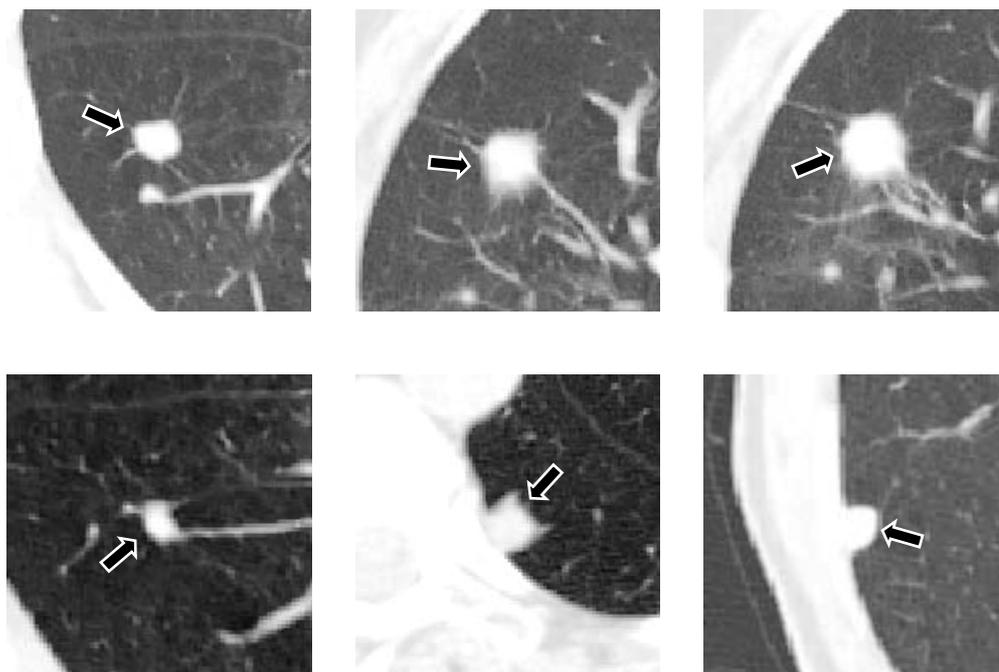


Figura 2 - Exemplos de nódulos pulmonares.
Fonte: Campos (2008).

Durante a fase de suposição da doença, a radiografia entra como primeiro passo para a sua identificação, sendo responsável por encontrar a maioria das suspeitas de nódulo pulmonar. Entretanto, sua baixa resolução não evidencia muitos detalhes que o caracterize, podendo até mesmo, ser confundido com fraturas nas costelas e regiões mais opacas.

A tomografia computadorizada é o método não-invasivo mais utilizado para caracterização do nódulo pulmonar, facilitando enormemente o estudo do procedimento mais correto para biópsias ou cirurgias, isto porque sua resolução permite exibir informações imperceptíveis numa radiografia. A Figura 3 exemplifica algumas estruturas do pulmão na tomografia computadorizada de uma caixa torácica. É importante salientar que nódulos pulmonares com menos de 2 cm têm uma probabilidade de cerca de 80% de ser benigno, entretanto, o pequeno tamanho desses achados não exclui a possibilidade de malignidade, pois 15% dos nódulos malignos têm menos de 1cm, enquanto que 42% são menores do que 2 cm de diâmetro (SZARF; SOUZA, 2009).

² Tumor benigno originado pelo crescimento desorganizado de células a partir do tecido normal e para de crescer uma vez que suas células se maturam.

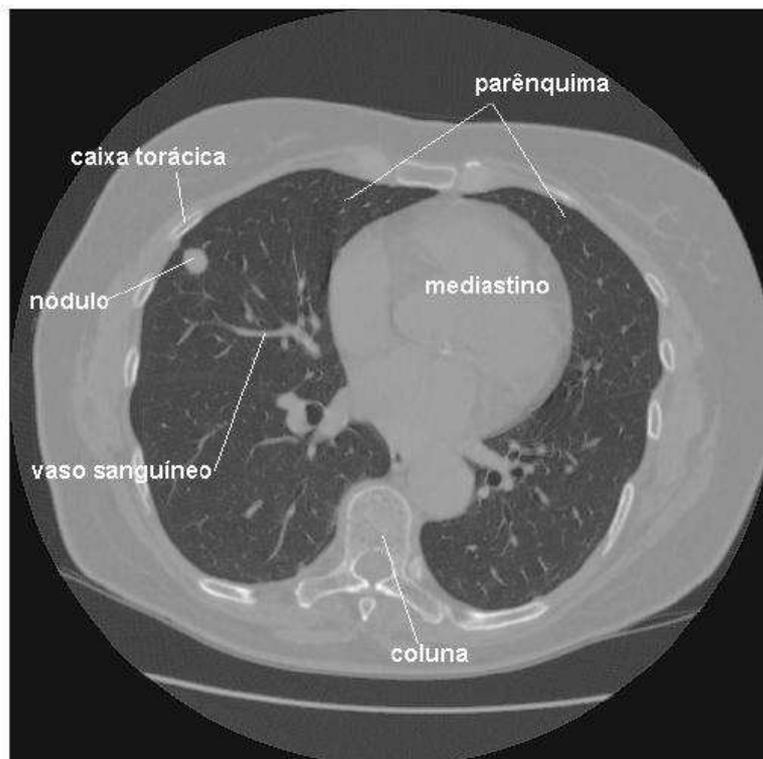


Figura 3 - Estrutura pulmonar identificada em uma Tomografia Computadorizada da Caixa Torácica.
Fonte: Souza (2007)

Nódulos pulmonares ainda podem ser classificados morfológica e topologicamente. Quanto à morfologia, o nódulo pode ser liso, rugoso ou lobulado, irregular ou espiculado. O aspecto liso do nódulo é um bom indicativo de benignidade, contudo, 21% dos nódulos malignos também apresentam essa característica. A presença de gordura e algum padrão de calcificação também podem oferecer algum indicativo de benignidade.

No que se refere à topologia de nódulos pulmonares, esta se relaciona com a localização do nódulo e seu efeito em conjunto com a forma e sua evolução deste nódulo, podendo sugerir princípios para sua classificação. Portanto, os seguintes princípios devem ser obedecidos com base nos dados acima que se encontram justificados a seguir segundo Tarantino (1997 apud SILVA, 2004):

a) Modificação temporal-evolutiva;

- O tempo de duplicação de uma lesão situa-se entre 30 e 450 dias, e seu achado será sugestivo de malignidade. Para que um nódulo

atinja 1 cm de diâmetro, a partir de uma única célula neoplásica, o tempo exigido é de dois anos e meio a 25 anos;

- Uma lesão que se duplique em menos de sete dias sugere fortemente que sua natureza seja benigna.

b) Presença e tipos de calcificação (ões);

- A calcificação difusa, da subtotalidade da lesão, é um achado muito sugestivo de benignidade;
- Mais de 30% das lesões não calcificadas podem ser consideradas de natureza benigna;
- A calcificação em nódulos malignos é um achado pouco freqüente, mas não raro, e pode ocorrer por alteração distrófica, ossificação do tumor ou inclusão de granuloma calcificado previamente existente, que em geral é excêntrico e discreto.

c) Tamanho absoluto da lesão;

- Menos de 5% das lesões benignas têm mais de 3 cm;
- Lesões menores de 1 cm, identificadas na tomografia computadorizada do tórax, tanto podem ser de natureza maligna como benigna.

d) Interface nódulo-parênquima;

- Configuração lobulada com limites espiculados são indícios fortes de malignidade,
- Contornos lisos e regulares (não lobulados), sem infiltração do parênquima circunjacente, são sugestivos, porém não conclusivos, de benignidade,
- Configuração regular com limites precisos (circunscritos, sem espículas) em uma lesão que sofre de modificação da forma com a mudança de decúbito, é muito sugestiva de lesão cística de conteúdo líquido e em sua grande maioria, benigno.

e) Variação de densidade após impregnação de contraste endovenoso.

O diagnóstico definitivo de malignidade, contudo, é dado apenas pelo exame citopatológico³ do material obtido por procedimentos que estão se tornando de menor morbidade, como a biópsia transbrônquica e transtorácica.

2.2 Tomografia Computadorizada

A tomografia, derivada da palavra grega “*tomos*”, que significa corte ou fatia, e “*grafos*”, que significa desenhar uma imagem ou gráfico, emprega os mesmos princípios da radiografia convencional cujo objetivo é criar uma representação anatômica baseada na quantidade de atenuação sofrida pela radiação incidente.

A tomografia computadorizada (TC) surgiu em meados de 1969, através dos trabalhos de Sir Godfrey Hounsfield (SOARES, 2006), que projetou um sistema eletrônico de detecção do feixe de radiação e de um processo de formação das imagens, e de Allan M. Cormack, que desenvolveu toda a matemática necessária para a reconstrução das imagens tomográficas, revolucionando a forma de sua aquisição.

Seu funcionamento é basicamente semelhante ao do raio X convencional, onde um feixe de raios X estreito gerado por um cabeçote é registrado por um detector ligado diametralmente, recebendo a radiação atenuada, dependendo da densidade e número atômico médio do tecido analisado e cuja intensidade é dada em unidades de Hounsfield (HU - *Hounsfield Unit*). A construção da imagem seccional em nível de cinza é obtida por um movimento rotação do conjunto cabeçote-detector, que após um movimento completo de rotação, é iniciado um novo processo de varredura, pelo deslocamento da mesa de alguns décimos de milímetro, até passar por todo o eixo axial do corpo do paciente

O tomógrafo computadorizado pode ser dividido, em três grandes partes, conforme ilustrado na Figura 4,:

³ O exame citopatológico é feito para estudar as alterações celulares, principalmente as do núcleo das células.

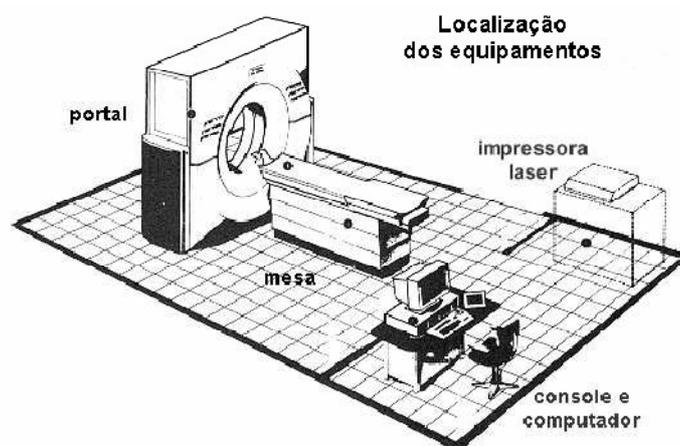


Figura 4 - Partes de um tomógrafo computadorizado.
Fonte: Soares (2006).

- O portal, que é composto pelo cabeçote contendo a ampola de raios X e o detector das radiações atenuadas que está diametralmente oposto;
- A eletrônica de controle e aquisição dos dados, responsável pela monitoração dos sensores e comandos aos dispositivos servo-mecânicos, e pela transdução dos sinais captados pelo detector que são enviados ao computador para a reconstrução da imagem;
- Console de comando e computador, isto é, *software* encarregado de gerenciar toda a estrutura do tomógrafo computadorizado e da formação das imagens, e o *hardware* no qual este programa é executado, respectivamente.

As características essenciais do aparelho de tomografia computadorizada (TC) que o diferenciam da radiografia simples são: a não sobreposição de estruturas; melhor contraste (menos radiação espalhada); detectores otimizados; e o processamento das imagens. Permitindo uma detecção mais precisa de nódulos inferiores a 1 cm.

A matriz de imagem seccional formada no cálculo computacional pelo *software* do aparelho está em nível de cinza com magnitude expressa em uma escala de contraste de Hounsfield usando como referência diversas substâncias como a água (entre 0 e ± 10), o osso cortical denso (entre 1000 a 3000) e o ar (com valor igual a -1000). O campo de reconstrução das imagens é chamado de FOV (*Field Of View*) sendo dado pelo produto entre o tamanho

da matriz da imagem e a dimensão do *pixel*, definindo o tamanho do objeto em estudo.

2.2.1 Imagens DICOM

As técnicas de detecção e diagnóstico a partir da obtenção de imagens médicas têm aumentado significativamente. Para tanto, a normalização entre o padrão de geração das imagens médicas torna-se necessário entre os vários modelos de equipamentos existentes a fim de promover uma melhor comunicação entre os fabricantes dos modelos de equipamentos, hospitais, clínicas, médicos especialistas e pesquisadores.

Nesse contexto, o padrão *Digital Imaging and Communications in Medicine* (DICOM), criado pela American College of Radiology (ACR) e o National Electrical Manufacturers Association (NEMA) em um comitê em 1983, surgiu com o objetivo de padronizar o formato das imagens através da criação de uma série de regras internacionalmente aceitas para a comunicação de informações biomédicas, de diagnóstico e terapêuticas. Ele permite que imagens médicas e informações associadas à imagem, ao paciente, ao aparelho e ao instituto responsáveis pela aquisição, sejam trocadas entre equipamentos de imagem, computadores e hospitais, estabelecendo uma linguagem comum entre os equipamentos, objetivando a melhor eficiência no fluxo de dados (CLUNIE, 2000), principalmente com o uso de *Picture Archiving and Communications Systems* (PACS), que propiciam a criação de bases de dados (NEMA, 2004).

A terceira versão do padrão DICOM (NEMA, 2004) engloba um grande número de características, entre as quais se destacam:

- É aplicável a ambiente de redes;
- Especifica como os equipamentos que usam o padrão DICOM devem reagir a comando e dados utilizados;
- Especifica níveis de conformidade para as aplicações;
- Está estruturado em documentos de múltiplas partes de forma a facilitar a evolução do protocolo;

- Introduce o conceito de objetos da informação, não somente para imagens e gráficos, mas para estudos e relatórios;
- Utiliza uma técnica de identificação única dos objetos de informação.

O padrão DICOM (NEMA, 2004) facilita a comunicação de equipamentos por especificar: conjunto de protocolos a serem seguidos pelas aplicações e equipamentos, a sintaxe e semântica dos comandos do protocolo e das informações associadas e os requisitos mínimos de conformidade.

Contudo, não especifica os detalhes de uma implementação, não garante a interoperabilidade entre equipamentos, e não especifica procedimentos para teste de validação (BARROS NETTO, 2008).

O padrão DICOM define um conjunto de objetos de informação (*Information Object* – IO) que correspondem a objetos do mundo real (imagem de TC, imagem de ressonância magnética, estudo e etc.) e os serviços ou operações (aquisição, impressão, armazenamento e etc.) realizados por uma entidade da aplicação (equipamento ou software) formando um par serviço-objeto (aquisição, impressão, armazenamento ou comunicação de uma imagem), gerados por uma modelagem de todas as informações do mundo real, desde a consulta do paciente até o processo de aquisição da imagem no TC.

2.3 Sistema de Auxílio à Detecção e Diagnóstico

Ao longo das últimas duas décadas, com o avanço da informática, foram propostos métodos e ferramentas Computacionais de Auxílio à Detecção (*Computer-Aided Detection* - CAD) e Diagnóstico (*Computer-Aided Diagnosis* - CADx) de nódulos pulmonares em imagens de tomografia computadorizada. Eles foram desenvolvidos para prover uma segunda opinião ao radiologista e especialista. Tipicamente esses sistemas detectam regiões suspeitas e classificam essas regiões observadas.

Os computadores podem auxiliar os médicos a encontrar áreas anormais em uma tomografia. O sistema buscará por combinações espaciais

na imagem, dificilmente perceptíveis ao olho humano. Tais combinações formaram o padrão reconhecido para uma região suspeita de anormalidade.

A avaliação de exames de imagem por médicos, com auxílio de um sistema CADx, diminui as taxas de erro (GIGER, 2000). Observa-se ainda uma redução na sobrecarga do médico, pois este, depois de avaliar certa quantidade de exames, fica, naturalmente, cansado, o que pode comprometer a precisão de seus diagnósticos.

Um sistema CADx geralmente divide-se em três etapas principais conforme Figura 5: segmentação da imagem de entrada para a obtenção de regiões de interesse; caracterização das regiões de interesse por meio de textura e/ou geometria; classificação das regiões de interesse através de um classificador, com o treinamento supervisionado baseado em diagnósticos feitos por um radiologista.

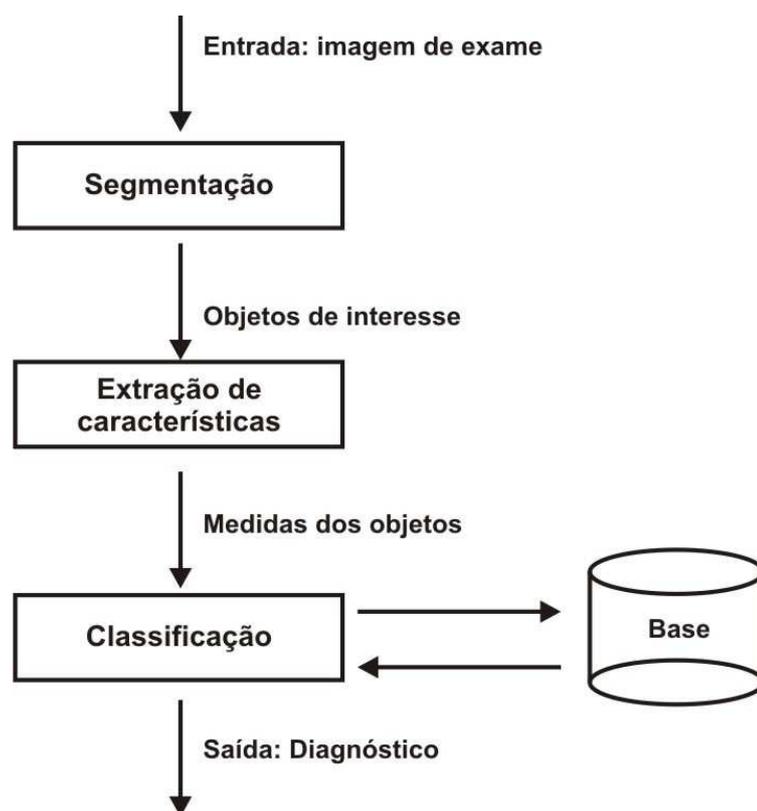


Figura 5 - Fluxo de funcionamento de um *software* CADx típico.
Fonte: Martins (2007).

A segmentação é usada para dividir o exame em regiões de interesse, de atributos similares. Em uma TC, por exemplo, a segmentação é usada para separar as possíveis estruturas de interesse do restante da imagem. Tal tarefa

pode ser extremamente difícil, visto que a proximidade entre nódulo e outras estruturas é muito grande na maioria dos casos.

Uma vez que o nódulo em potencial está separado do restante da imagem, o sistema então extrai as principais características de textura e geometria dessa região suspeita. Na etapa seguinte, o objeto é submetido à avaliação de um classificador, que, baseado em um treinamento realizado previamente, informa ao sistema se o objeto em questão corresponde ou não a um diagnóstico positivo de malignidade em um nódulo pulmonar. Maiores detalhes sobre segmentação, característica de textura e geometria, e algoritmos de classificação serão vistos nas seções seguintes.

Quanto às aplicações, existem diversas possibilidades. Existem ferramentas CADx para auxílio no diagnóstico de nódulos em exames mamográficos, de tórax e outros. Existem sistemas de análise de sinais cardíacos e cerebrais. Eles podem, ainda, ser utilizados na avaliação tecidos lesionados, etc. Inumeráveis são as situações aplicáveis e, talvez em alguns anos, eles estejam presentes, ao lado do médico, em todas as etapas de sua atividade.

Para alcançar seus objetivos, sistemas CADx tipicamente utilizam diversas técnicas de processamento de imagens que incluem técnicas de extração de características baseadas em estatística, morfologia matemática, descrição e reconhecimento de padrão, dentre outras. Esses sistemas aplicados a problemas da área da saúde se valem do poder computacional para realizar inúmeras tarefas que possam chegar a um resultado conclusivo a respeito de onde o especialista humano deve procurar primeiro por alguma anormalidade. Os conceitos utilizados para criar uma metodologia CADx serão abordados a seguir iniciando-se com os principais conceitos em processamento de imagens digitais. Em seguida, as próximas seções abordarão sobre a fundamentação teórica básica e necessária para o desenvolvimento da metodologia.

2.4 Processamento de Imagens Digitais

O processamento de imagens digitais é compreendido como um conjunto de técnicas computacionais que abrangem desde a aquisição da imagem digital até seu reconhecimento e interpretação por parte de uma máquina digital. Nesse contexto, uma imagem digital é definida como uma função bidimensional $f(x,y)$, sendo x e y as coordenadas espaciais e a amplitude de f para um dado ponto (x,y) é chamada de intensidade ou *pixel* (*picture element*). É importante ressaltar que todos os valores de x , y e respectivas intensidades devem ser quantidades finitas e discretas, e que uma imagem digital apresenta um número finito de pontos x e y . Em imagens 3D, como as imagens de tomografia computadorizadas utilizadas neste trabalho, esse representação elementar do ponto, agora com coordenadas espaciais x , y e z , é chamada de *voxel* (*volume element*).

O interesse em métodos de processamento imagens digitais surgiu, principalmente, da necessidade de melhorar a qualidade da informação pictorial para interpretação humana. Uma das primeiras aplicações das técnicas de processamento de imagens digitais que se tem registro foi a melhoria de ilustrações de jornais enviados por cabo submarino entre Londres e New York por volta de 1920 (GONZALEZ; WOODS, 2000).

As imagens são produzidas por uma variedade de dispositivos físicos, tais como câmeras fotográficas e vídeo câmeras, equipamentos de radiografia, microscópios eletrônicos, magnéticos e de força atômica, radares, equipamento de ultra-som, entre vários outros. A produção e utilização de imagens podem ter diversos objetivos, que vão do puro entretenimento até aplicações militares, médicas ou tecnológicas. O objetivo da análise de imagens, seja por um observador humano ou por uma máquina, é extrair informações úteis e relevantes para cada aplicação desejada (GONZALEZ; WOODS, 2000).

Processamento de Imagens vem na realidade do Processamento de Sinais. Os sinais, como as imagens, são na realidade suportes físicos que carregam no seu interior uma determinada informação (ALBUQUERQUE; ALBUQUERQUE, 2006). Esta informação pode estar associada a uma medida (neste caso falamos de um sinal em associação a um fenômeno físico), ou

pode estar associada a um nível cognitivo (neste caso falamos de conhecimento). Processar uma imagem consiste em transformá-la sucessivamente com o objetivo de extrair mais facilmente a informação nela presente (ALBUQUERQUE; ALBUQUERQUE, 2006).

Na prática o processamento de imagens é uma técnica extremamente dependente do problema que queremos resolver. Normalmente, as técnicas de processamento de imagens estão baseadas em métodos matemáticos que permitem descrever quantitativamente imagens das mais diversas origens (SONKA; HLAVAC;BOYLE, 1998).

Ao longo das duas últimas décadas, a área de processamento de imagens digitais apresentou um rápido crescimento. A evolução da tecnologia de computação digital, bem como o desenvolvimento de novos algoritmos para lidar com sinais bidimensionais estão permitindo uma gama de aplicações cada vez maior.

Através das técnicas de processamento de imagens digitais é possível melhorar o aspecto visual de certas feições estruturais para o observador humano e fornecer outros elementos para a interpretação visual da imagem, podendo inclusive gerar outros produtos que possam ser posteriormente submetidos a outros processamentos. Além disso, o reconhecimento e interpretação por parte da máquina propiciam inúmeras vantagens. A visão humana é sensível somente a uma pequena faixa do espectro eletromagnético, enquanto que máquinas podem ser projetadas para cobrir desde radiação *gamma* até ondas de rádio.

Programas computacionais podem ser treinados para interpretar imagens que apresentam difícil interpretação por parte de seres humanos, tais como as imagens de ultra-som e microscopia eletrônica (GONZALEZ; WOODS, 2000). Tudo isso faz com que a área de processamentos de imagens digitais englobe um largo e variado campo de aplicações. Exemplos de áreas em que tais técnicas computacionais têm sido empregadas com sucesso são: astronomia, medicina, física, arqueologia, biologia, defesa e aplicações industriais.

Muitas áreas da saúde têm sido favorecidas com a grande variedade de aplicativos e pesquisa desenvolvidos na área de processamento de imagens médicas, os chamados sistemas CAD/CADx. Embora seja uma área de

pesquisa relativamente nova, favorecida principalmente com o advento de equipamentos de exames digitais, o processamento de imagens digitais já conquistou avanços consideráveis que estão sendo usados por vários setores da saúde principalmente como ferramentas de auxílio a diagnóstico, acompanhamento ou detecção.

Na medicina, por exemplo, o processamento de imagens digitais permite a coloração ou a intensificação de contraste para facilitar a interpretação de radiografias e outras imagens biomédicas e até mesmo realizar detecções e diagnósticos de maneira automática, fornecendo assim uma segunda opinião aos profissionais de saúde.

O processamento de imagens digitais segue várias etapas. O fluxograma padrão dessas etapas é representado na Figura 6. Dentre as etapas necessárias após a definição e delimitação do problema, estão aquisições das imagens digitais, pré-processamento, segmentação, representação e descrição, reconhecimento e interpretação. O conjunto de resultados gerados por uma etapa é utilizado na etapa seguinte. Algumas etapas não recebem ou geram imagens digitais como resultados. Assim, ao final de todo o processamento, o resultado pode ou não ser caracterizado por uma imagem digital.

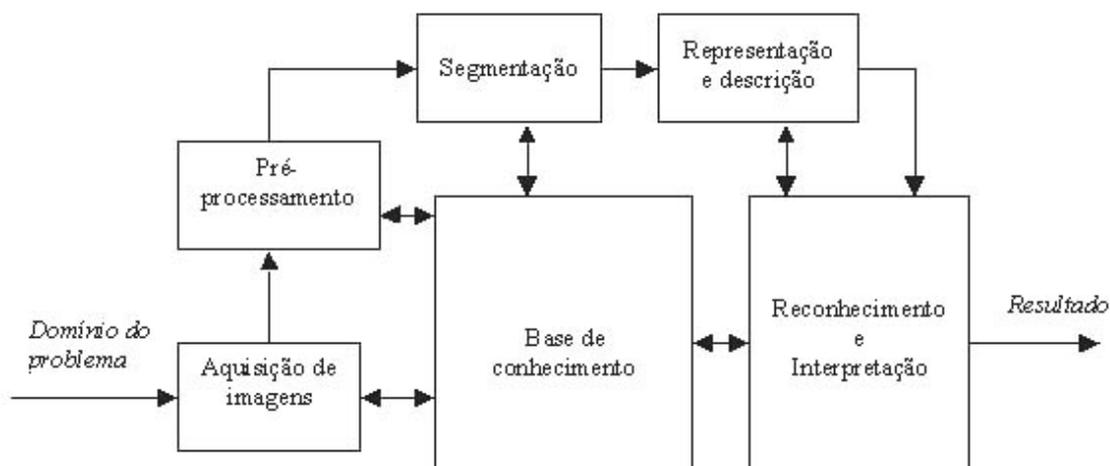


Figura 6 - Passos fundamentais em processamento de imagens digitais.
Fonte: Adaptado de Gonzalez (1992).

A aquisição é o primeiro passo para o processamento de imagens digitais. O equipamento que converte uma imagem analógica para digital é

chamado de digitalizador. Um digitalizador é um equipamento em que o sinal, de vídeo de uma câmara de TV, ou de intensidade de um laser transmitido ou refletido, é aplicado a um conversor analógico-digital (ADC). A voltagem de cada ponto, correspondente ao seu brilho (intensidade), é expressa pelo binário (inteiro) mais próximo. Esse processo é chamado de amostragem do sinal analógico em forma digital. Em nosso trabalho, a aquisição de imagens é feita usando exames de tomografia computadorizadas.

O passo seguinte é de pré-processamento da imagem. A função dessa etapa é tornar certas estruturas da imagem mais simples de serem definidas. Técnicas de realce ou melhoramento de imagens são usadas nessa etapa. Podemos citar: a diminuição de ruído, realce de contraste, filtros morfológicos e etc.

O terceiro passo na metodologia de processamento de imagem é a segmentação cujo objetivo é simplificar a imagem, reduzindo-a aos seus componentes básicos (objetos ou segmentos). Dessa forma, a segmentação pode ser considerada como qualquer operação que distinguir os objetos contidos na imagem, ou de alguma forma isolá-los entre si. Na segmentação, as imagens são divididas em regiões distintas de forma a produzir outras regiões que apresentem maior homogeneidade entre os elementos contidos nesta região e ainda fazendo cada região bem diferente em relação as demais regiões.

Como a segmentação é muito dependente do problema que se está abordando (tipo de imagem) não existe na literatura um método geral para aplicação em todas as categorias de imagens (SOUZA, 2007). A segmentação pode ser realizada de três maneiras: manual, semi-automática e automática.

Na segmentação manual todo o processo de separação de um objeto de interesse é conduzido por um especialista humano. Só se faz necessário para realização desse processo, ferramentas que auxiliem o especialista de forma visual para a separação da área de interesse. Na segmentação semi-automática, tem-se uma ferramenta que processa informações sobre o que procurar na imagem ou em local procurar para identificar regiões de interesse. Na segmentação automática não existe nenhum conhecimento *a priori* do que buscar na imagem. O método deverá ter a habilidade de separar as várias regiões da imagem em conjuntos desconexos de acordo com critérios de

similaridade entre cada região. Aplicamos a etapa da segmentação para extrair o nódulo das demais estruturas da caixa torácica.

O passo de representação e descrição pode ser chamado extração de características. Seu objetivo é determinar características básicas de cada objeto que resultem em informações importantes para discriminação entre classes distintas. O conjunto dessas medidas constitui um vetor de características que definem um padrão calculado para aquela determinada área. Em nosso trabalho, essa etapa consiste na extração de características do nódulo segmentado.

Na etapa de Reconhecimento e Interpretação de imagens digitais, o objetivo é classificar, através de uma base de conhecimento, o objeto em algum grupo determinado previamente. A metodologia apresentada, consiste na classificação dos nódulos como benigno ou maligno a partir da descrição desses nódulos, obtida na etapa anterior.

As seções seguintes apresentam o embasamento teórico dos principais passos utilizados neste trabalho.

2.5 Segmentação

A segmentação é um dos mais importantes passos para a análise de dados de imagens. Em Sonka; Hlavac; e Boyle (1998) a segmentação é definida como sendo a delimitação de regiões de interesse dentro de uma imagem para uma aplicação específica.

A segmentação é considerada, dentre todas as etapas do processamento de imagens, a etapa mais crítica do tratamento da informação. É nesta etapa que são definidas as regiões de interesse para processamento e análises posteriores. Conseqüentemente, quaisquer erros ou distorções presentes nesta etapa se refletem nas demais etapas, de forma a produzir ao final do processo resultados não desejados que possam contribuir de forma negativa para a eficiência de todo o processamento (GONZALEZ; WOODS, 2000). As seções seguintes tratam das técnicas de segmentação utilizadas neste trabalho.

2.5.1 Limiarização ou *Thresholding*

O processo de limiarização ou *thresholding* pode ser considerado uma forma simples de segmentação, a qual consiste em particionar uma imagem em regiões com características semelhantes. Uma constante (limiar) de intensidade poder ser determinada para segmentar o objeto e o fundo da imagem.

Existem basicamente dois tipos de limiarização: a limiarização global e a limiarização adaptativa. Dado um valor de limiar t e o número de bits por *pixel* b , a limiarização global particiona a imagem em duas regiões, uma com os níveis de cinza entre 0 e t , e outra com níveis de cinza entre $t+1$ e 2^b-1 . A limiarização adaptativa, por outro lado, busca encontrar limiares diferentes para regiões diferentes da imagem, melhorando a qualidade do resultado final. Diversas técnicas podem ser utilizadas para encontrar o melhor valor do limiar para uma imagem (GONZALEZ; WOODS, 2000). Uma das mais simples consiste em examinar o histograma da imagem, verificando se existem “vales” ou “depressões” entre dois máximos. O valor mínimo entre esses dois máximos é um bom candidato a limiar global.

A seguir, aborda-se o método de (OTSU, 1979), a técnica de segmentação que foi utilizada para segmentar os nódulos pulmonares provenientes da base de dados LIDC (*Lung Image Consortium Database*).

2.5.1.1 Método de Otsu

A técnica de limiarização de Otsu (OTSU, 1979) é um método automático de segmentação de imagens em níveis de cinza, usando dados estatísticos do histograma da imagem como base para escolha de um valor de limiar eficaz (SOARES, 2001). Este limiar pretende minimizar a variância intraclasse de *pixels* ou *voxels* (em imagens 3D) de baixas e altas densidades e maximizar a variância entre as classes, como por exemplo, encontrar um valor ótimo que separe o objeto e fundo em uma imagem. A Figura 7 exemplifica histogramas de baixa bimolaridade e de alta bimolaridade onde o

método de Otsu pode de ser aplicado para encontrar uma discriminação em grupos (objeto x fundo), principalmente para os casos de baixa densidade obtidos no histograma.

Segundo FACON (2009), o método de Otsu apresenta característica de natureza não paramétrica e não supervisionada para a seleção de limiar e possibilita as seguintes vantagens:

- a) O processo é muito simples; são utilizados somente os momentos cumulativos zero e de primeira ordem do histograma de níveis de cinza;
- b) Pode ser usado como uma solução direta para problemas que exijam vários limiares;
- c) Um limiar ótimo (ou conjunto de limiares) é selecionado de forma automática e estável, baseado na propriedade global do histograma e não propriedade local como um vale;
- d) Viabiliza a análise de outros aspectos importantes, tais como estimativa dos níveis médios das classes, avaliação da separabilidade das classes, etc.;
- e) O método é extremamente genérico; cobre um largo escopo de processos de decisão não supervisionados.

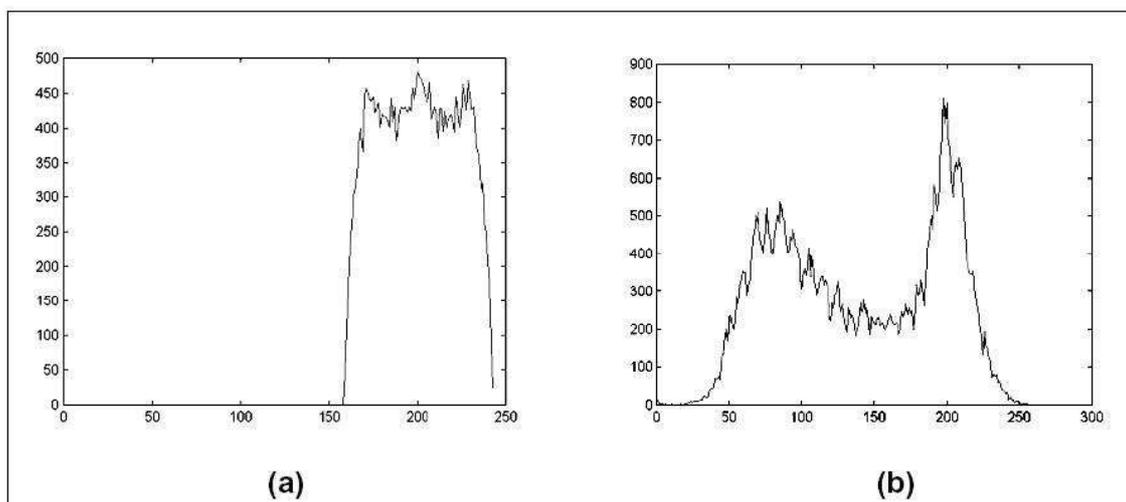


Figura 7 - (a) Histograma com bimodalidade baixa; (a) Histograma com bimodalidade alta.
Fonte: Soares (2001).

No Apêndice A é descrita a teoria sobre o método Otsu, onde são explanados o cálculo do limiar ótimo e as medidas de variância entre as classes.

2.5.2 Crescimento de regiões 3D

A segmentação por crescimento de região é um procedimento que agrupa *pixels* ou sub-regiões em regiões maiores em que uma abordagem de agregação de *pixels* é estabelecida. Essa abordagem considera que uma semente é colocada em uma região de interesse, ou seja, em um objeto ao qual se deseja isolar, e cresce gradativamente à medida que encontra *pixels* com características semelhantes, de acordo com o critério utilizado.

A segmentação baseada em crescimento de região é um método que agrega pixels que possuam propriedades similares conforme ilustrado na Figura 8. Por esta razão, deve-se usar um critério de homogeneidade para a região de interesse e para tal uso faz-se necessário ter uma noção de que pontos servem como boas sementes para o início do algoritmo. Este critério de homogeneidade pode ser o nível de cinza, a cor, a textura, forma ou algum modelo (SONKA; HLAVAC; BOYLE, 1998).

Quando a segmentação é tridimensional, um conjunto de imagens define os objetos que se deseja segmentar (NIKOLAIDIS apud SILVA, 2004). Portanto, um intervalo de imagens precisa ser especificado para a atuação do método, como um mecanismo de controle do processo. O procedimento ocorre conforme ilustrado na Figura 9.

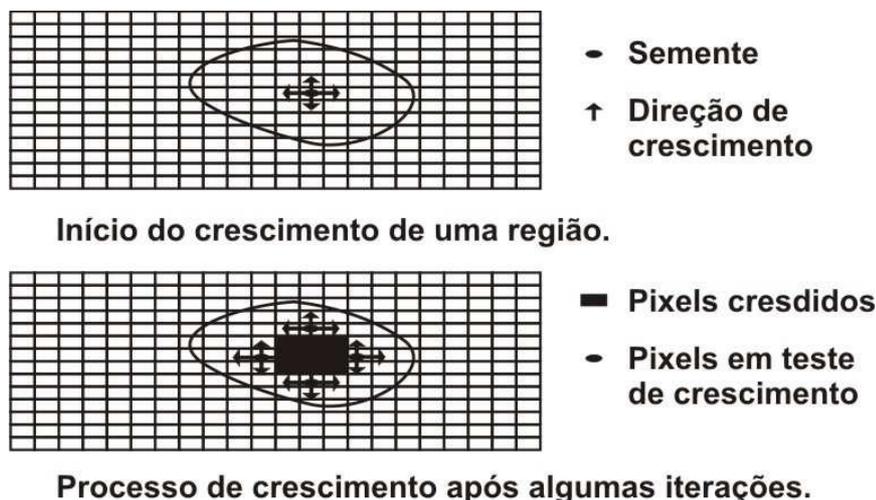


Figura 8 - Crescimento por região a partir de uma semente.
Fonte: Silva (2001).

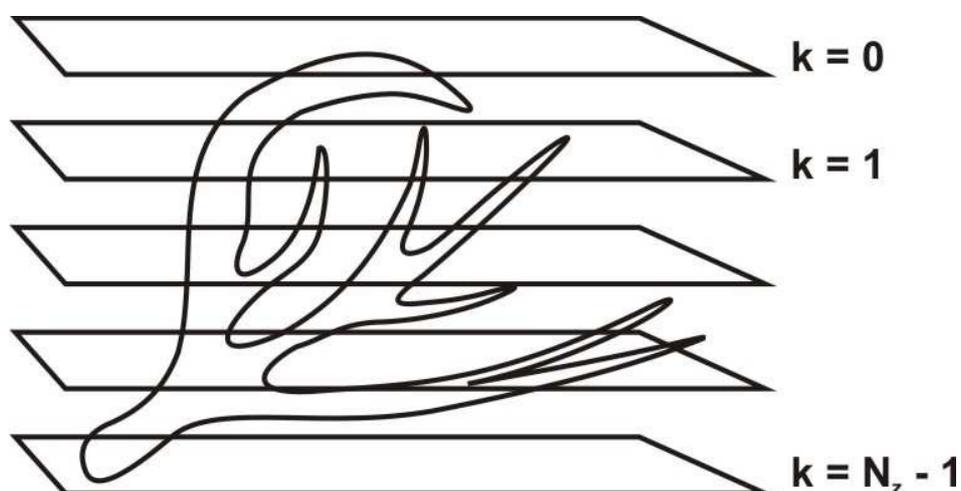


Figura 9 - Crescimento de região 3D estabelecido nas diversas fatias.
Fonte: Silva (2001).

2.6 Representação e Descrição

Segundo Gonzalez e Woods (2000) a representação e descrição da agregação dos *pixels* resultantes da segmentação em um formato aplicável para um processamento computacional adicional torna-se necessária para etapas posteriores como a etapa de classificação, por exemplo.

A escolha de uma representação é apenas parte da solução para transformar os dados iniciais numa forma adequada para o subsequente processamento computacional. Um método para descrever os dados também

deve ser especificado, de forma que as características de interesse sejam enfatizadas.

O processo de descrição, também chamado seleção de características, procura extrair características que resultem em alguma informação quantitativa de interesse ou que sejam básicas para discriminação entre classes de objetos (GONZALEZ; WOODS, 2000).

2.6.1 Análise de Textura

A textura é uma característica que visivelmente se descreve, porém, seu conceito é impreciso. Sonka (1998) descreve como sendo um conjunto de elementos mutuamente relacionados formando blocos de textura que são agrupados em primitivas chamadas de *texels* (*texture elements*) e dependente da escala. Pode ser descrito pela sua tonalidade ou estrutura (MARTINS, 2007).

A tonalidade está relacionada às propriedades do *pixel*, enquanto que a estrutura descreve a espacialidade das primitivas. Quando a textura é fraca, podemos descrevê-las através das frequências dos tipos de primitivas que aparecem na vizinhança. Já a textura forte, pode ser avaliada melhor por meio da avaliação da frequência dos pares de primitivas por possuir definição exata (SONKA; HLAVAC; BOYLE, 1998).

Uma melhor descrição das texturas pode ser dada pela estatística. A estatística de descrição da textura tem como objetivo medir as propriedades lineares das primitivas, usando o *pixel* para avaliar suas correlações, e “dizer”, se a mesma é uma textura grossa com largas primitivas e baixas frequências ou texturas finas de primitivas menores e altas frequências. Estas correlações são feitas por diversos cálculos, como o coeficiente de auto-correlação, análise de Fourier e a matriz de co-ocorrência (SONKA; HLAVAC; BOYLE, 1998).

O coeficiente de auto-correlação mede a forte relação em uma vizinhança de um ponto. A análise de Fourier mede o valor médio da energia no anel. Enquanto, a matriz de co-ocorrência é uma estatística de segunda ordem que mede a frequência de alguma configuração de nível de cinza que se verifica em determinadas direções e a sua classificação pode ser feita usando

cálculos de energia, entropia, máxima probabilidade, contraste, momento da diferença inversa e a correlação.

Outras formas de obtenção de medidas de texturas têm sido buscadas através do uso de funções geoestatísticas para determinar a correlação espacial entre os padrões de textura (análise espacial entre pares de *pixels* em imagens 2D ou pares de *voxels* em imagens 3D) conforme (SILVA et al., 2007, 2008). Na seção seguinte será abordado o Índice de Simpson que será utilizado neste trabalho como medida de textura.

2.6.1.1 Índice de Simpson

Criado em 1949, por E. H. Simpson (SIMPSON, 1949), o Índice de Simpson é uma medida estatística de segunda ordem que tem sido usado por especialistas em ecologia para determinar a biodiversidade de espécies em uma região. Sua principal funcionalidade é resumir a representação dessa diversidade em um único valor capaz de qualificar esta região como bastante heterogênea ou uniforme.

Como exemplo, tome-se a seguinte situação: numa região há duas comunidades com cem indivíduos e dez espécies diferentes. Uma comunidade possui dez indivíduos para cada espécie a outra possui um indivíduo em cada uma das nove espécies e 91 indivíduos para a décima espécie. Como determinar a mais diversificada sendo que ambas possuem a mesma quantidade de espécies? Segundo Ricklefs (1993), o Índice de Simpson leva em consideração a riqueza das espécies, isto é, o número de espécies presentes numa área, e ainda a regularidade da espécie, que é uma medida de abundância relativa de cada espécie. Com essas considerações é possível analisar qual comunidade em uma região é mais diversificada.

A obtenção do Índice de Simpson é dada da seguinte forma:

Para cada espécie i , é encontrada a probabilidade (p_i) da ocorrência da espécie i como demonstrado na Equação 1, onde n_i representa a ocorrência de indivíduos da espécie i e N o total de indivíduos na amostra.

$$p_i = \frac{n_i}{N} \quad (1)$$

O Índice de Simpson é a medida de probabilidade de dois indivíduos, selecionados aleatoriamente de uma amostra, pertencerem à mesma espécie i entre as J espécies existentes na amostra conforme Equação 2.

$$D = \sum_{i=1}^J p_i^2 \quad (2)$$

Segundo (LYONS, 2009), para uma amostra finita o Índice de Simpson pode ser obtido ainda através da seguinte expressão:

$$D = \frac{\sum_{i=1}^J n_i(n_i - 1)}{N(N - 1)} \quad (3)$$

Os valores obtidos para o Índice de Simpson estão no intervalo entre 0 e 1, onde o valor 0 representa diversidade infinita na amostra e 1 representa que não há diversidade na amostra.

Retomando o exemplo citado e calculando o Índice de Simpson da Equação 3 para cada comunidade, obteve-se o resultado de 0,09 para a primeira comunidade e 0,82 para segunda comunidade. Estes resultados concluem que a primeira comunidade, por apresentar valor do índice próximo à zero é bem mais diversa que a segunda comunidade.

Para uma melhor interpretação do resultado do Índice de Simpson, uma medida similar pode ser obtida: Índice de Simpson de Diversidade conforme Equação 4. Ela indica a variação de diversidade da amostra, isto é, reflete que quanto mais diversa for a amostra, menos provável será que dois indivíduos selecionados aleatoriamente pertençam a mesma espécie. Seus valores também se encontram no intervalo de 0 a 1 porém, 0 indica nenhuma diversidade e 1 amostra completamente heterogênea.

$$Id = 1 - D \quad (4)$$

Outra variante do Índice de Simpson é obtida através da Equação 5 e denominada Índice de Simpson Recíproco. Seu menor valor encontrado é 1 e caracteriza a amostra como homogênea. Quanto maior o valor desse índice, maior a diversidade. O valor máximo assumido é referente ao número de espécies na amostra.

$$Ir = \frac{1}{D} \quad (5)$$

Neste trabalho, o Índice de Simpson, apresentado na Equação 3, é utilizado para medir a diversidade na distribuição dos *voxels* nas regiões de interesse de um volume de um nódulo. O objetivo é utilizar o valor obtido com o índice para caracterizar a textura das regiões segmentadas, complementando com as informações geométricas e fornecendo os subsídios necessários para o reconhecimento de um padrão que possibilite ao classificador distinguir entre nódulos malignos e benignos.

2.6.2 Análise de Geometria

Em processamento de imagens, a informação de textura, às vezes, não é suficiente para separar adequadamente os objetos de interesse em classes distintas. Por isso, medidas geométricas são utilizadas como informação adicional para caracterizar os objetos segmentados.

Há vários descritores ou medidas geométricas que são relatadas na literatura de processamento de imagens (UNIVERSITY OF GUELPH, 2001). No entanto, neste trabalho foram utilizadas as seguintes medidas geométricas para caracterizar nódulos pulmonares como benignos e malignos: densidade esférica, desproporção esférica e esfericidade. Todas essas medidas foram avaliadas por Souza (2007) onde se encontrou resultados significativos para caracterização de nódulos pulmonares. No mesmo trabalho o autor ainda propôs três novas medidas. Elas são obtidas então a partir dos nódulos segmentados. Considerou-se, para efeito de cálculo das medidas, somente as propriedades geométricas como áreas e volume. As medidas são apresentadas a seguir.

2.6.2.1 Desproporção Esférica

Nódulos pulmonares benignos e malignos são, morfológicamente, diferentes, principalmente quando observados em três dimensões. Conforme descrito anteriormente, nódulos pulmonares benignos podem apresentar aspectos mais arredondados enquanto que os nódulos pulmonares malignos podem apresentar formas alongadas.

Utilizar uma medida que seja capaz de mensurar o quanto determinado objeto tem sua superfície irregular com relação a uma superfície totalmente esférica, ou seja, estimar, através da comparação entre a área que o objeto tem e uma possível área que esse objeto teria se fosse totalmente esférico é uma forma qualitativa de diferenciar estruturas conforme sua morfologia.

A medida de desproporção esférica mede a regularidade das bordas de um objeto. Esta medida é calculada através da Equação 6, na qual A é a área da superfície do objeto, R é o raio estimado da esfera com o mesmo volume do objeto. O raio é obtido através da Equação 7, sendo V o volume do objeto.

$$\text{DespEsf} = \frac{A}{4\pi R^2} \quad (6)$$

$$R = \sqrt[3]{\frac{3V}{4\pi}} \quad (7)$$

Desta forma, segundo Sousa (2007), a desproporção esférica assume valores menores para objetos esféricos e valores maiores para objetos alongados ou irregulares.

2.6.2.2 Densidade Esférica

Nódulos pulmonares têm formato semelhante à esfera e outras estruturas como vasos, veias etc, têm pouca semelhança com a mesma (SOUSA, 2007).

Medidas geométricas bastantes comuns consistem em comparar a área de um objeto com sua *bounding box* (caixa mínima), isto é, o menor retângulo ou menor cubo, para objetos 3D, capaz de armazenar o objeto. Essas medidas, entretanto, enfrentam o problema de calcular o melhor alinhamento da figura circunscrita, ou seja, o problema de obter uma figura circunscrita com as menores dimensões possíveis através de um posicionamento desta em torno do objeto inscrito de forma a reduzir as regiões entre a borda objeto e o perímetro da figura. Alinhamento este que sofre com a situação em que um mesmo objeto produz valores diferentes de alinhamentos devido a rotações no objeto.

Sendo essas medidas rotacionalmente variantes, a densidade esférica, por outro lado, utiliza uma esfera, que é uma figura rotacionalmente invariante, para estimar qual a porcentagem da esfera que também corresponde ao objeto (SOUSA et al., 2008). A densidade esférica é uma medida que mede quão compacto é um objeto comparando o seu volume em relação ao volume de uma *bounding box*.

Utilizando uma esfera cujo volume seja o mesmo do objeto em análise e com origem no centro de massa deste, a medida de densidade esférica consistirá na porcentagem desta esfera que, de fato, também corresponda ao objeto. A Figura 10 ilustra, em duas dimensões, o conceito de densidade esférica para diferentes objetos.

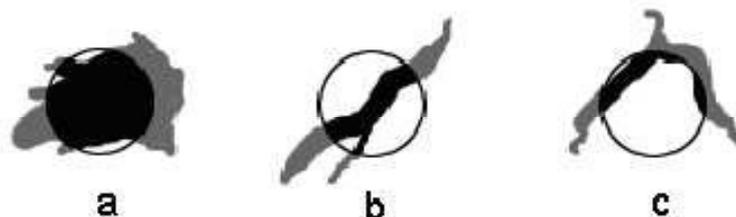


Figura 10 - Ilustração da densidade esférica de três objetos em duas dimensões.
Fonte: Souza (2007).

A densidade esférica é calculada pela Equação 8, na qual n é o número de voxels $V_{x,y,z}$ tais que $V_{x,y,z} \neq 0$ e $(x - M_x)^2 + (y - M_y)^2 + (z - M_z)^2 \leq R^2$, R é o volume do objeto, R é o raio estimado obtido pela Equação 7 e M_x , M_y e M_z são as coordenadas do centro de massa do objeto dada pela Equação 9.

$$\text{DensEsf} = \frac{100 \cdot n}{V} \quad (8)$$

$$M_x = \frac{\sum V_x}{n}, M_y = \frac{\sum V_y}{n}, M_z = \frac{\sum V_z}{n} \quad (9)$$

A densidade esférica tende a assumir valores próximos a zero para objetos muito alongados e valores próximos a 100 para objetos mais arredondados.

2.6.2.3 Esfericidade

A esfericidade mede quanto o formato do objeto aproxima-se de um formato esférico. É calculada através da Equação 10, onde V é o volume do objeto e A é área da sua superfície.

$$\text{Esf} = \frac{(6V)^{\frac{2}{3}} \pi^{\frac{1}{3}}}{A} \quad (10)$$

2.7 Reconhecimento de Padrões

Os seres humanos são capazes de reconhecer padrões com grande rapidez. Faz parte da natureza humana, ao observar um objeto, fazer uma coleta de informações, as quais são comparadas com as propriedades e

comportamentos conhecidos e armazenados em sua mente. Através dessa comparação os seres humanos são capazes de reconhecer o alvo de sua observação. Este conceito de reconhecimento é simples e familiar para todos em um ambiente real, mas no contexto da inteligência artificial, o reconhecimento não é uma tarefa trivial. Não existe nenhuma máquina ou software de inteligência artificial que seja capaz de igualar-se a capacidade de reconhecimento do cérebro humano.

As iniciativas para o reconhecimento automático de padrões dividem-se em duas categorias: reconhecimento de itens concretos e abstratos. O reconhecimento de itens concretos envolve o reconhecimento de impressões digitais, assinaturas, objetos físicos, formas de ondas, voz, faces, enfim, o reconhecimento de itens que existem concretamente. Os elementos abstratos seriam itens sem forma física como, por exemplo, a solução para um determinado problema.

O reconhecimento de padrões envolve três níveis de processamento: filtragem da entrada, extração de características e classificação. A filtragem da entrada de dados tem o objetivo de eliminar dados desnecessários ou distorcidos fazendo com que a entrada apresente apenas dados relevantes para o reconhecimento do objeto em análise. A extração de características consiste da análise dos dados de entrada a fim de extrair e derivar informações úteis para o processo de reconhecimento.

O estágio final do reconhecimento de padrões é a classificação, onde através da análise das características da entrada de dados o objeto em análise é declarado como pertencente a uma determinada categoria. Quando se busca realizar o reconhecimento de padrões em modelos estáticos, em especial a fase de classificação que é bastante onerosa, esses modelos são eficientes apenas quando suposições de limite são satisfeitas.

Segundo Silva (2007), na análise de imagens, chama-se de objeto ou padrão a representação de uma imagem segmentada. Um conjunto de objetos pode ser dividido em regiões ou grupos que, do ponto de vista de classificação, tem alguns fatores comuns; tais grupos são chamados de classes. Em Sonka; Hlavac; e Boyle (1998) é definido que a forma como os objetos são distribuídos nessas classes dependem do objetivo da classificação. O número de classes normalmente é previamente conhecido e deriva da especificação do problema.

Existem diversas técnicas formais para o reconhecimento de padrões, entre as quais se destacam os métodos estatísticos e os baseados em redes neurais (GONZALEZ; WOODS, 2000).

Na seção seguinte será exposto, brevemente, o embasamento teórico que fundamenta a técnica utilizada para o reconhecimento de padrões nesse trabalho.

2.7.1 Classificadores

A classificação é uma tarefa relativamente fácil para o ser humano visto que ele recebe sinais do mundo exterior através dos sentidos e em seguida identifica padrões e classifica os sinais.

Segundo Wiley (2000), classificadores são técnicas que procuram determinar a que grupo uma amostra selecionada pertence. São, tipicamente, representados por funções discriminantes. Uma função discriminante associa um escore a todo ponto no espaço de entrada. Cada grupo tem sua função individual, que dá valores mais altos pelos pontos que pertencem a determinado grupo. Então, cada amostra é associada ao grupo com o maior discriminante.

Na seção seguinte, aborda-se as Máquinas de Vetores de Suporte, uma técnica de classificação baseada no conhecimento adquirido através de um processo de aprendizagem.

2.7.1.1 Máquina de Vetores de Suporte

A Máquina de Vetores de Suporte (MVS) é considerada um sistema de aprendizagem que utiliza um espaço de hipóteses de funções lineares em um espaço de muitas dimensões. Proposta por Vapnick (1995), a MVS é um método de aprendizagem supervisionada usado inicialmente para estimar uma função que classifique dados de entrada em duas classes.

A idéia básica por trás da Máquina de Vetores de Suporte é construir um hiperplano como superfície de decisão, de tal maneira que a margem de

separação entre as classes seja máxima. O objetivo do treinamento através da MVS é a obtenção de hiperplanos que dividem as amostras de tal maneira que sejam otimizados os limites de generalização (BURGES, 1998).

Os algoritmos de treinamento das MVS possuem forte influência da teoria de otimização e de aprendizagem estatística. Em poucos anos, as MVS vêm demonstrando sua superioridade frente a outros classificadores em uma grande variedade de aplicações (CRISTIANINI; SHAW, 2000).

Em casos em que o conjunto de amostras é composto por duas classes separáveis, um classificador MVS é capaz de encontrar um hiperplano baseado em um conjunto de pontos, denominados *vetores de suporte*.

Por hiperplano entende-se uma superfície de separação de duas regiões em um espaço multidimensional, onde o número de dimensões possíveis pode ser, até, infinito. Mesmo quando as duas classes não são separáveis, a MVS é capaz de encontrar um hiperplano através do uso de conceitos pertencentes à teoria da otimização. A Figura 11 mostra em duas dimensões, para melhor visualização, hiperplanos de separação entre duas classes linearmente separáveis. O hiperplano ótimo (linha mais escura), não somente separa as duas classes, mas mantém a maior distância possível com relação aos pontos da amostra.

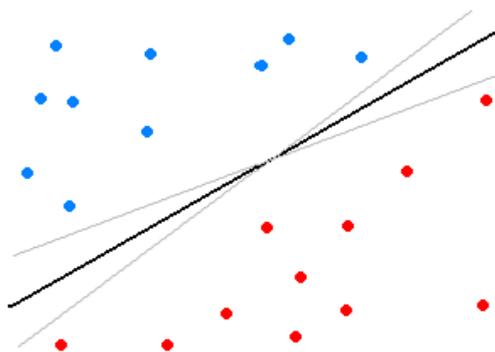


Figura 11 - Separação de duas classes através de hiperplanos.
Fonte: Martins (2007).

Existem duas abordagens para MVS: MVS tradicional e MVS de uma classe. Na MVS tradicional, a classificação dos dados é feita atribuindo os dados a duas classes bem definidas e conhecidas *a priori*. Supõe-se que o conjunto de dados é igualmente equilibrado na amostra entre as classes. Um

conjunto de dados desbalanceado pode levar a resultados não conclusivos (SCHÖLKOPF; SMOLA, 2002). Um problema comum desta abordagem é que o hiperplano de decisão cria a separação ótima. Caso as amostras utilizadas contenham informações correspondentes ou mesmo exista um desbalanceamento no número de elementos de cada classe, a MVS pode gerar uma taxa de erro de classificação não desejada para esses casos (MANEVITZ, 2001).

Uma variação da MVS é utilizada com a criação do hiperplano de separação para apenas uma classe rotulada como positiva. A MVS de uma classe (*One-Class SVM*) tem rendimento melhor que a MVS tradicional em separar dados de interesse dos demais, porque gera uma hiper-esfera de decisão que limita apenas uma classe das demais que possam existir (MANEVITZ, 2001). A estratégia é mapear os dados no espaço de características e, em seguida, englobar o máximo de amostras da mesma classe em uma hiper-esfera de decisão. Dessa forma, a metodologia precisa conhecer *a priori* apenas uma classe, conjuntos de dados desbalanceados não influenciam na decisão do classificador e podem ser utilizados sem problemas de desempenho. Todavia, a MVS de uma classe é muito sensível a classes fortemente acopladas entre si ou que contenham muita heterogeneidade intraclasse.

Nas seções seguintes, descreve-se brevemente a teoria básica aplicada em cada tipo de MVS. Neste trabalho, são realizados testes de classificação com os dois tipos de MVS.

2.7.1.1.1 MVS tradicional

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

A etapa de treinamento estima a função $f(x) = (wx) + b$ procurando por valores de w e b tais que a seguinte relação seja satisfeita:

$$y_i((w \cdot x_i) + b) \geq 1 \quad (11)$$

Sendo w o vetor normal ao hiperplano de decisão e b o corte ou distância da função f em relação á origem. Os valores ótimos de w e b serão encontrados ao minimizar a função dada na Equação 12, de acordo com a restrição dada pela Equação 11 (CHAVES, 2006).

$$\Phi(w) = \frac{w^2}{2} \quad (12)$$

onde Φ é a função de projeção de w sobre o hiperplano de separação.

A MVS ainda possibilita encontrar um hiperplano que minimize a ocorrência de erros de classificação nos casos em que uma perfeita separação entre as duas classes não for possível. Isso graças à inclusão de variáveis de folga, que permitem que as restrições presentes na Equação 11 sejam quebradas.

O problema de otimização passa a ser então a minimização da Equação 13, de acordo com a restrição imposta pela Equação 11, C é um parâmetro de treinamento que estabelece um equilíbrio entre a complexidade do modelo e o erro de treinamento e deve ser selecionado pelo usuário.

$$\Phi(w, \xi) = \frac{w^2}{2} + C \sum_{i=1}^N \xi_i \quad (13)$$

onde C é uma penalidade para a função Φ , ξ_i é a variável de folga que suaviza as restrições dada pela equação 14 , e N é o número de amostras de entrada.
para

$$y_i((w \cdot x_i) + b) + \xi_i \geq 1 \quad (14)$$

Através da teoria dos multiplicadores de Lagrange, chega-se à Equação 15. O objetivo então passa a ser encontrar os multiplicadores de Lagrange α_i ótimos que satisfaçam a Equação 16 (CHAVES, 2006).

$$L(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j (x_i x_j) \quad (15)$$

$$\sum_{i=1}^N \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq C \quad (16)$$

onde C é uma penalidade para a função Φ .

Apenas os pontos onde a restrição dada pela Equação 11 é exatamente igual à unidade têm correspondentes $\alpha_i \neq 0$. Esses pontos são chamados de vetores de suporte, pois se localizam geometricamente sobre as margens. Tais pontos têm fundamental importância na definição do hiperplano ótimo, pois os mesmos delimitam a margem do conjunto de treinamento.

A Figura 12 destaca os pontos que representam os vetores de suporte. Os pontos além da margem não influenciam decisivamente na determinação do hiperplano, enquanto que os vetores de suporte, por terem pesos não nulos, são decisivos.

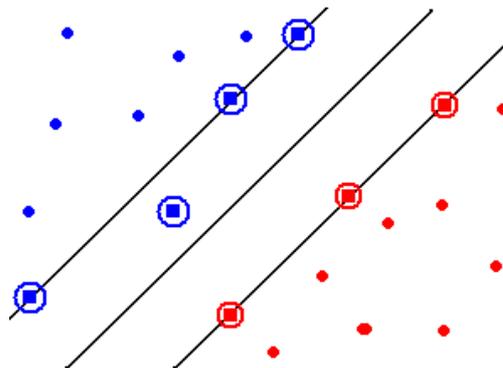


Figura 12 - Vetores de suporte (destacados por círculos).
Fonte: Martins (2007).

Para que a MVS possa classificar amostras que não são linearmente separáveis, é necessária uma transformação não-linear que transforme o espaço entrada (dados) para um novo espaço (espaço de características).

Esse espaço deve apresentar dimensão suficientemente grande, e através dele, a amostra pode ser linearmente separável. Dessa maneira, o hiperplano de separação é definido como uma função linear de vetores retirados do espaço de características ao invés do espaço de entrada original. Essa construção depende do cálculo de uma função K de núcleo de um produto interno (HAYKIN, 2001). A função K pode realizar o mapeamento das amostras para um espaço de dimensão muito elevada sem aumentar a complexidade dos cálculos.

A Equação 17 mostra o resultado da Equação 15 com a utilização de um núcleo K .

$$L(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j K(x_i x_j) \quad (17)$$

Uma importante família de funções de núcleo é a família de funções de base radial, muito utilizada em problemas de reconhecimento de padrões e também utilizada neste trabalho. A função de base radial é definida por:

$$K(x_i, x_j) = \exp\left(-\gamma \|x_i - x_j\|^2\right) \quad (18)$$

onde $\gamma = 1 / \sigma^2$, sendo σ a variância.

2.7.1.1.2 MVS de uma classe

A MVS de uma classe foi proposta em Schölkopf et al. (1999), para estimar os vetores de suporte de uma distribuição dimensional alta. Dado um conjunto de dados, sem quaisquer informações sobre as classes, a MVS de uma classe constrói uma função de decisão que toma valores positivos em uma pequena região capturando a maior parte dos pontos de dados, e as amostras negativas em outra região.

O processo inicia com um conjunto de amostras de treinamento:

$$x = \{x_i | i = 1, 2, 3, \dots, l\} \quad (19)$$

onde l é o número de amostras. Considere que cada amostra x no espaço de entrada é mapeada para um ponto $z = \Phi(x)$ de uma distribuição dimensional alta. O objetivo é separar, no espaço de características, os dados de origem com máxima margem. Dado um vetor de treinamento x_i sem nenhuma informação da classe, a forma primária da função de projeção Φ , segundo Schölkopf (2001) é:

$$\min_{w, b, \xi, \rho} \frac{1}{2} w^T \cdot w - \rho + \frac{1}{vl} \sum_{i=1}^l \xi_i$$

$$\text{sujeito a } [w^T \cdot \Phi(x_i)] \geq \rho - \xi_i \quad (20)$$

$$\xi_i \geq 0, i = 1, \dots, l$$

onde w é o vetor normal do hiperplano que representa a fronteira de decisão, ρ representa o limiar da função de erros e ξ_i são as variáveis de folga que penalizam os erros de treinamento. O parâmetro v $[0,1]$ está associado com relação entre o raio da hiper-esfera de formação e o número de amostras de treinamento que se pode reter.

A forma dual é:

$$\min \frac{1}{2} \alpha^T Q \alpha$$

$$\text{sujeito a } 0 \leq \alpha_i \leq 1, i = 1, \dots, l \quad (21)$$

$$e^T \alpha = vl$$

onde $Q_{ij} = K(x_i, x_j) \equiv \Phi(x_i)^T \Phi(x_j)$. A função de núcleo K mapea o espaço de entrada no espaço de características. A função de decisão é:

$$f(x) = \text{sgn} \left(\sum_{i=1}^l \alpha_i K(x_i, x) - \rho \right) \quad (22)$$

2.8 Avaliação dos Resultados

Em geral, a avaliação dos resultados obtidos de uma classificação não determina uma verdade absoluta sobre o diagnóstico. O que se consegue é atribuir probabilidades para uma determinada resposta, isto é, uma classificação apresenta um grau de certeza sobre o diagnóstico. No uso de máquinas de aprendizagem para a tarefa de classificação, os melhores resultados são obtidos a partir de um conjunto de rotinas de treino e teste e depois analisando sua capacidade de predição ou generalização em decorrência de casos novos.

Para o diagnóstico de presença de doença ou ausência, os resultados são em geral dicotômicos. Essa dicotomia leva a avaliação para estimativa de acertos e erros. Isto que dizer que os testes de validação consideram dois resultados obtidos para poder calcular essas estimativas. São eles: o resultado preditivo, o que foi obtido no teste após o aprendizado, e o resultado real, a correta identificação do diagnóstico segundo análises clínicas.

Quando se avalia um teste diagnóstico para determinar se existe doença ou não em um determinado paciente, quatro situações são possíveis:

1. O teste é positivo e o paciente tem a doença - Verdadeiro Positivo (VP);
2. O teste é positivo, mas o paciente não tem a doença - Falso Positivo (FP);
3. O teste é negativo e o paciente tem a doença - Falso Negativo (FN) e
4. O teste é negativo e o paciente não tem a doença - Verdadeiro Negativo (VN).

Geralmente, utilizam-se algumas estatísticas descritivas para avaliar o desempenho do classificador, como Sensibilidade (S), Especificidade (E), Acurácia (A), Valor Preditivo Positivo (VPP) e Valor Preditivo Negativo (VPN).

A sensibilidade de um teste é definida pela proporção de pessoas com a doença de interesse que têm o resultado do teste positivo. Indica quão bom é o teste para identificar os indivíduos doentes:

$$S = \frac{VP}{VP + FN} \quad (23)$$

A especificidade de um teste é a proporção de pessoas sem a doença que tem o teste negativo. Indica quão bom é o teste para identificar os indivíduos não doentes:

$$E = \frac{VN}{VN + FP} \quad (24)$$

A taxa de classificação correta (acurácia ou precisão) é definida como a razão entre o número de casos na amostra em estudo que foram classificados corretamente e o número total de casos na amostra em estudo.

$$A = \frac{TP + TN}{TP + TN + FP + FN} \quad (25)$$

O Valor Preditivo Positivo (VPP) do teste diagnóstico é, portanto, a probabilidade de uma pessoa com um resultado positivo ter a doença, expressa por:

$$VPP = \frac{VP}{VP + FP} \quad (26)$$

O Valor Preditivo Negativo (VPN) do teste é a probabilidade de uma pessoa com resultado negativo não ter a doença, expressa por:

$$VPN = \frac{VN}{FN + VN} \quad (27)$$

A fim de avaliar a metodologia quanto ao seu poder de caracterizar os grupos propostos, procurou-se obter medidas de sensibilidade, especificidade e acurácia para as análises realizadas no estudo. Logo, os nódulos pulmonares

malignos corretamente contabilizados são relatados como verdadeiros positivos.

3 METODOLOGIA

A metodologia proposta neste trabalho visa classificar nódulos pulmonares solitários em dois grupos: benignos e malignos. Para a realização dessa tarefa, esta metodologia baseou-se nos passos mostrados na Figura 13. O primeiro passo é a aquisição da imagem, que foi obtida de exame de TC de tórax de um paciente. Nesta etapa utilizamos duas diferentes fontes de aquisição. Na primeira, as imagens foram cedidas pelo Instituto Fernandes Figueira e o Hospital Universitário Pedro Ernesto, cedidas devido a um intercâmbio em pesquisas. Na outra, as imagens foram disponibilizadas pelo Arquivo Nacional de Imagens de Câncer dos EUA (NCIA – *National Cancer Imaging Archive*), que é um repositório de pesquisa de imagens de câncer, criado com a finalidade de prover acesso a imagens de câncer para uso no desenvolvimento e validação de ferramentas CAD/CADx.

O segundo passo é a segmentação do volume tridimensional do nódulo, no qual se usou um algoritmo de crescimento de região para uma base de dados de imagens e utilizou-se o método de Otsu na outra. Em seguida, no terceiro passo, são obtidas as medidas representativas dos nódulos através da aplicação do Índice de Simpson e da extração de medidas de geometria, isto é, a etapa da análise de textura e geometria. O último passo é o uso da Máquina de Vetores de Suporte para determinar a classificação das medidas dos nódulos como benignos ou malignos.

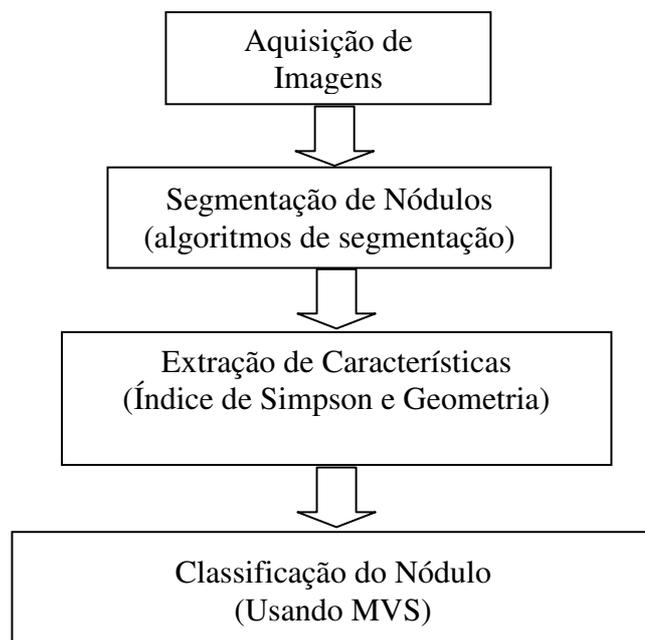


Figura 13 - Passo da Metodologia.

3.1 Aquisição das Imagens

Nesta seção, descreve-se o processo de aquisição das imagens para a segmentação dos nódulos e extração de características. Obteve-se imagens de duas diferentes fontes. As fontes de aquisição foram denominadas de Base I, para a origem através do Instituto Fernandes Figueira e o Hospital Universitário Pedro Ernesto e de Base II para a origem através do *Lung Image Database Consortium* (LIDC) (MCNITT-GRAY et al., 2004). Nas próximas subseções aborda-se sobre cada base de imagens.

3.1.1 Base I

Foram obtidas as imagens no formato DICOM através dos exames de Tomografia Computadorizada, autorizados pelos pacientes para que fossem utilizadas em pesquisas. Os exames foram realizados pela equipe técnica dos institutos já mencionados que estão localizados no estado do Rio de Janeiro, Brasil.

O equipamento utilizado na aquisição foi um tomógrafo helicoidal GE Pro Speed sob as seguintes condições: voltagem do tubo de 120 kVp, corrente do tubo de 100 mA, tamanho padrão da imagem de 512 x 512 pixels, tamanho médio do *voxel* de 0,67mm x 0,67mm x 1,00mm e quantização de 12 bits de acordo com o padrão DICOM de armazenamento empregado (NEMA, 2004). Ao total foram obtidos 39 nódulos (30 benignos e 9 malignos).

É importante informar que os exames foram realizados sem a injeção de contraste iodado nos pacientes, que pode ser clinicamente usado como melhoramento do diagnóstico, mas, que também causa problemas alérgicos e mortes ocasionais. Destaca-se, ainda, que os resultados de um diagnóstico como benigno ou maligno foi confirmado por um médico especialista através de exame histopatológico feito com remoção cirúrgica de uma amostra do nódulo ou pela radiologia após três anos de estabilidade. Isto explica o tamanho reduzido da base de dados.

3.1.2 Base II

Foram obtidas imagens disponibilizadas através do Instituto Nacional do Câncer dos EUA (NCI) a partir da criação de um repositório de imagens de câncer que é resultado da formação de um consórcio entre cinco universidades norte-americanas, que é conhecido como LIDC.

O LIDC é um grupo que procura estabelecer um formato padrão e processos de gerenciamento de imagens de pulmão, relatórios técnicos e dados clínicos necessários para o desenvolvimento, treinamento, e evolução de algoritmos para detectar e diagnosticar câncer de pulmão.

A base LIDC fornece um documento com a informação do contorno para nódulos pulmonares maiores que 3 mm, enquanto que para aqueles inferiores a 3 mm, apenas o centróide é fornecido. O contorno do nódulo é definido ao longo das fatias, assim como a sua classificação, por quatro especialistas e disponibilizados em um arquivo XML. Dessa forma, de 84 exames disponíveis nesta base, apenas 58 exames possuem informação do contorno. Um contorno é formado por pares de pontos de coordenadas (x,y) que delimitam, em cada imagem do exame, a região onde o especialista identificou o nódulo.

Na descrição da característica nodular há uma escala de classificação que permite ao especialista uma maior subjetividade a respeito do nódulo. De acordo com esta escala, consideram-se, neste trabalho, como nódulos malignos os casos que apresentaram características de altamente e moderadamente suspeito de malignidade e como nódulos benignos, os casos que apresentaram características de altamente e moderadamente indicadores de benignidade.

Considera-se, ainda, como nódulo a análise de cada especialista que classificasse e identificasse o contorno do nódulo. A LIDC utilizou o conhecimento de quatro especialistas. Então, essa consideração foi possível porque de acordo com o processo do protocolo de comunicação definido pelo LIDC, cada especialista faz suas anotações sobre um mesmo exame. Sendo assim é possível ter diferentes diagnósticos para um mesmo nódulo. Ao total foram obtidos 198 nódulos (99 benignos e 99 malignos).

3.2 Segmentação 3D dos Nódulos

Esta seção descreve o processo de segmentação utilizado em cada banco de imagens adquirido.

3.2.1 Segmentação da Base I

Na Base I, um processo de segmentação semi-automático foi executado por médicos especialistas que usam o Sistema de Análise de Nódulo Pulmonar, chamado *Bebúi* (SILVA; CARVALHO, 2002). Neste sistema, a fase automática usou um algoritmo de crescimento de região 3D com agregação de *voxel*, que também provê ao usuário maior interatividade e controla a segmentação por determinação de parâmetros exigidos como limiares, fatia inicial e final, e semente. Além disso, duas ferramentas adicionais foram incorporadas, barreira e borracha, para prover maior controle no procedimento de segmentação, correspondendo à segmentação semi-automática do sistema. A barreira é um cilindro colocado ao redor do nódulo pelo usuário com o propósito de restringir a região de interesse e evitando que agregação de *voxels* invada outras estruturas de pulmão. A borracha é um recurso do sistema que permite aos médicos apagar estruturas indesejadas, antes ou depois de segmentação, para evitar e corrigir erros de segmentação.

A segmentação semi-automática foi necessária porque as densidades dos voxels dos nódulos são semelhantes a outras estruturas, como vasos sanguíneos, pleura parietal e densidades pulmonares anormais localizadas que prejudicam a segmentação automática no caso de proximidade. O conhecimento da anatomia normal e patológica na radiologia torácica ajuda a distinguir entre estruturas diferentes e aperfeiçoar o processo. Assim, embora o algoritmo de crescimento de região 3D possa apresentar alguns erros de segmentação, o uso das ferramentas do *Bebúi* torna possível corrigir erros e minimizar enganos de segmentação. Na Figura 14 é exibido um procedimento de segmentação de um nódulo através do *Bebúi*.

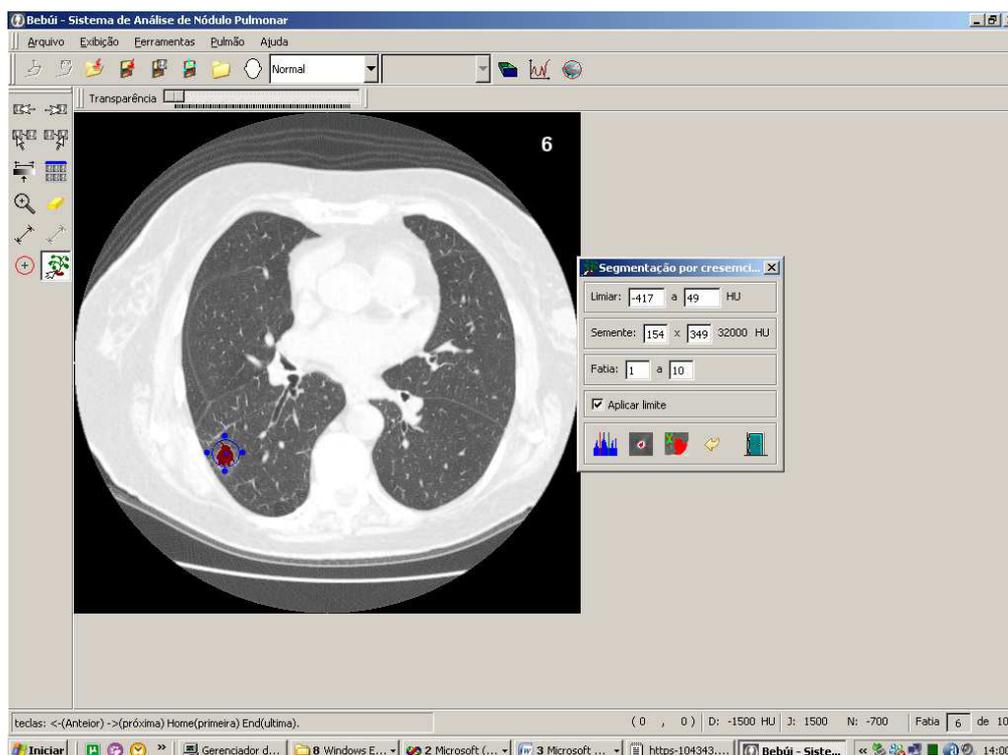


Figura 14 - Segmentação de nódulo utilizando o *software* *Bebúi*.

3.2.2 Segmentação da Base II

Para a segmentação dos nódulos da Base II, são obtidas informações do contorno do nódulo, conforme mencionado anteriormente, de um arquivo *XML*, onde se tem as informações dos pontos que envolvem a região ocupada pelo nódulo segundo critério de análise para cada especialista. Em seguida, o contorno é utilizado para gerar uma *bounding box* que contenha o volume do nódulo em questão. A *bounding box* será criada considerando os valores máximos e mínimos obtidos em cada eixo *x* e *y*. Ao longo do eixo *z*, o valor da *bounding box* é determinado pelo número de fatias ou imagens contida no exame. Logo após, é calculado o histograma dos *voxels* contidos na *bounding box* para que depois seja aplicada a segmentação pelo método de Otsu. Nessa segmentação, os *voxels* contidos na *bounding box* em cada imagem são comparados com um limiar de Otsu e quando eles têm valores maiores ou iguais ao limiar, são guardados para construção do volume segmentado do

nódulo. O objetivo do uso do método de Otsu para segmentar o nódulo, que já possui um contorno, é separar na região delimitada pela *bounding box*, os *voxels* que pertencem ao nódulo dos demais. O resultado de um nódulo segmentado pelo método de Otsu com o contorno preenchido é mostrado na Figura 15. A Figura 15(a) apresenta o contorno preenchido do nódulo original marcado pelo especialista, na Figura 15(b), tem-se a visualização da *bounding box* gerada sobre o contorno preenchido e na Figura 15(c) o nódulo segmentado.

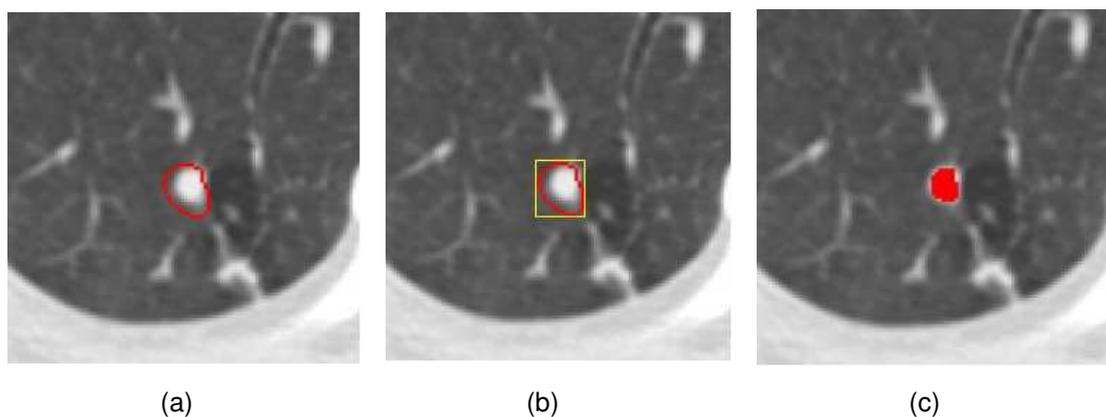


Figura 15 - Nódulo segmentado da base LIDC. (a) visualização do contorno preenchido original do nódulo, (b) geração da *bounding box* para o contorno preenchido e (c) nódulo segmentado pelo método de Otsu.

3.3 Extração de Características

Após a segmentação dos nódulos, são calculadas algumas características que possam representar esse nódulo em uma das classes objetivadas nesse trabalho. Nas subseções seguintes, são mostradas as formas de extração de características propostas.

3.3.1 Característica de Textura

O nódulo pulmonar solitário possui uma estrutura de tecido muito complexa. Podem existir nódulos com alterações de densidade quase imperceptíveis pelo olho humano e outras visíveis com grande nitidez. A

variação do tecido do nódulo e, conseqüentemente, a observação da TC pelo médico auxiliam no seu diagnóstico. Entretanto, por causa da qualidade da imagem, ou até mesmo pela constituição do tecido do nódulo, alguns detalhes passam despercebidos pelos médicos, o que pode levar a procedimentos desnecessários.

Com o objetivo de extrair uma assinatura de textura para a representação dos nódulos pulmonares segmentados, o Índice de Simpson apresentado na Equação 3 (Seção 2.6.1.1) foi calculado para cada nódulo. Na metodologia apresentada, a extração do Índice de Simpson é feita tomando cada possível valor de *voxel* encontrado no volume de um nódulo como sendo uma possível espécie em análise. Embora os valores dos *voxels* originais sejam altos, ao tentar utilizar a técnica de quantização nos volumes segmentados, observou-se que o resultado era bastante similar para os níveis de quantizações aplicados, fato que não contribui para a extração do índice, uma vez que se buscava a diversidade e por este motivo não foi dada continuidade na utilização da quantização.

Realizou-se a extração das medidas de textura aplicando duas formas distintas de análise. Na primeira, as medidas foram obtidas considerando as áreas de interesse formadas por esferas concêntricas conforme mostra a Figura 16. Cada área de interesse representa um experimento para o método. Na segunda análise, a área de interesse foi representada por anéis esféricos conforme a Figura 17. O objetivo com essas formas de extração é avaliar qual é a melhor maneira de utilização da medida de textura, considerando que a análise em esferas procura determinar diferenças nos padrões de diversidade para nódulos benignos e malignos em cada região de estudo desde a fronteira do nódulo até seu centro. Na análise em anéis procuramos avaliar a diversidade nas regiões de fronteira determinada por duas esferas concêntricas.

Determina-se o tamanho das esferas encontrando o ponto central, centro de massa, de cada nódulo e em seguida, calcula-se a medida de distância desse ponto central até o ponto mais distante de cada nódulo. Assim, tem-se um raio R que representa a maior medida possível para construção de uma esfera circunscrevendo o nódulo ou ainda, na análise em anéis, o máximo raio externo permitido. A partir do raio R , obtêm-se outros valores de raios

como $1/6R$, $1/3R$, $1/2R$, $2/3R$ e $5/6R$. Estes são representados como R_1 , R_2 , R_3 , R_4 , R_5 e R_6 a partir do valor de R . A quantidade de raios utilizadas para construir as regiões de extração da característica foi determinada empiricamente. Por tanto, ressalta-se que essa escolha é um critério dependente da abordagem adotada e pode ser variada entre metodologias ou estudos diferentes.

Para a abordagem em esferas, um determinado raio R_n , com $n=1, \dots, 6$, descreve uma região a ser explorada para a extração do Índice de Simpson. Assim o raio R_6 é referente à esfera mais externa obtida para um nódulo. Para a abordagem em anéis, um anel A_n , com $n=1, \dots, 5$, refere-se à uma região formada pela diferença entre duas esferas com raios consecutivos. Dessa forma, um anel A_1 , é uma região formada pela diferença entre os raios R_1 e R_2 . Portanto, o vetor de característica formado em ambas as análises e que será utilizado no classificador MVS é constituído apenas pela medida do Índice de Simpson na região.

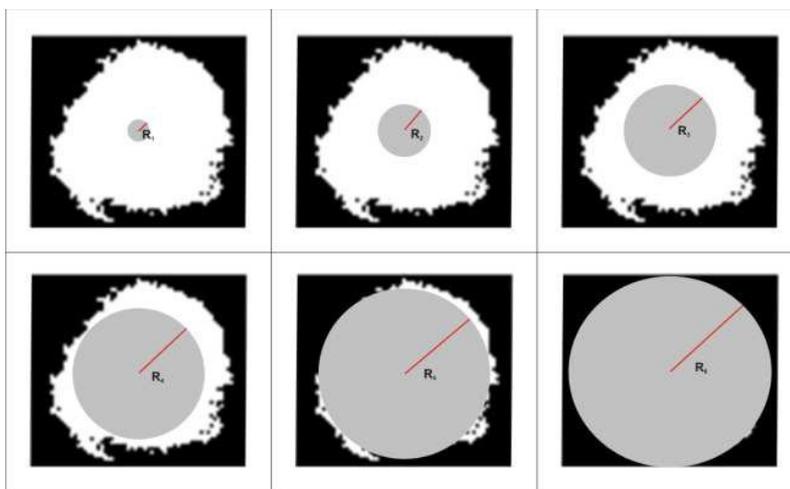


Figura 16 – Representação em 2D da Análise em Esferas Concêntricas contendo 6 raios aplicada ao nódulo.

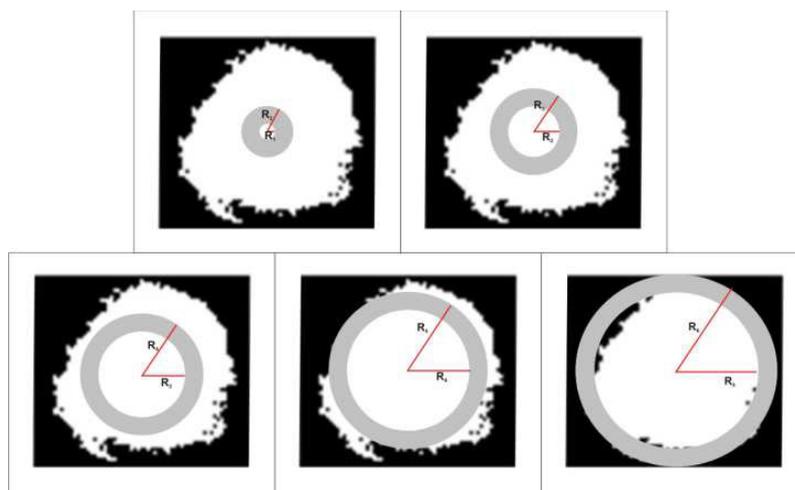


Figura 17 - Representação em 2D da Análise em Anéis Esféricos contendo 6 raios externos aplicada ao nódulo.

3.3.2 Característica de Geometria

A forma de um nódulo pulmonar pode representar um importante indicador de sua malignidade ou benignidade conforme dito anteriormente. Nesse sentido, procurou-se extrair as medidas de geometria abordadas na Seção 2.6.2 para avaliação nos classificadores utilizados. As medidas utilizadas foram aplicadas ao nódulo por inteiro, ou seja, considerando todo o seu volume, não se fez análises em regiões de estudo e nem se considerou o valor do *voxel* como fatores de influências para efeito de cálculo. O vetor de características a ser utilizado no classificador MVS é formado pelas três medidas de geometria apresentadas neste trabalho.

3.3.3 Característica de Textura e Geometria

A fim de aumentar o poder discriminatório da metodologia, juntou-se o Índice de Simpson da Equação 3 com as medidas de geometria expostas na Seção 2.6.2. O resultado desse conjunto de medidas é a formação de um vetor de características que leva em conta o valor do Índice de Simpson extraído em uma determinada região de análise em um nódulo acrescido das três medidas

de geometria calculadas para este nódulo. O objetivo é tentar fornecer ao classificador MVS os melhores aspectos dos dois tipos de medidas.

3.4 Classificação

O processo de classificação objetiva analisar os padrões obtidos através das extrações de características propostas usando o classificador MVS, tradicional e de uma classe, para verificar a eficiência desses padrões bem como os classificadores para o problema de diagnóstico de nódulos pulmonares como benignos ou malignos.

Para efeito de validação dos resultados e uso na MVS, as bases de amostras são formadas pelos nódulos obtidos em cada base de dados (Base I e Base II). Essas amostras foram divididas, aleatoriamente, em dois grupos: grupo de treino e grupo de teste. Os percentuais treino (Tr) e teste (Te) são apresentados na Tabela 1. No total, são utilizadas seis diferentes conjuntos de treino/teste (Tr/Te) para avaliar o desempenho da metodologia quanto ao aumento gradativo de amostras para treinamento e diminuição para teste. Os dados das amostras são normalizados em todas as características obtidas para uma faixa de valores entre -1 a 1. Essa operação ajuda o classificador MVS a convergir com maior facilidade na etapa de treinamento e também padroniza a distribuição de valores das variáveis que podem assumir diferentes domínios.

Durante a etapa de treinamento é gerado o modelo com os vetores de suporte utilizados pela MVS na etapa de teste. A etapa de treinamento desconhece por completo as amostras de testes. Esse mecanismo pretende se assemelhar com condições reais de teste. Com o modelo gerado, se torna possível realizar a etapa de reconhecimento de padrões com as amostras de teste separadas.

Conjunto Tr/Te	Treino	Teste
30/70	30%	70%
40/60	40%	60%
50/50	50%	50%
60/40	60%	40%
70/30	70%	30%
80/20	80%	20%

Para a MVS foi utilizado o núcleo radial da Equação 18 (Seção 2.7.1.1). Com a MVS tradicional usando a função de núcleo radial, é necessário estimar o melhor peso C e também o valor γ para a função radial. Os valores de C e γ são estimado através de uma busca exaustiva realizado pelo *script* desenvolvido em PYTHON: *grid.py* presente no pacote LIBSVM (CHANG e LIN, 2009). Esse *script* busca através de validação cruzada a melhor combinação de parâmetros para a base que retorne como resposta o melhor percentual de acerto total sobre dados de teste e treino na validação cruzada. Para o núcleo radial na MVS de uma classe, é necessário estimar o melhor ρ e também o valor γ para a função radial. Os valores de ρ e γ são estimados através de um algoritmo de validação cruzada, desenvolvido por (BRAZ JUNIOR, 2008), que apresenta a melhor combinação desses parâmetros com a melhor taxa de acerto para o conjunto (Tr/Te).

3.5 Softwares e Hardware utilizados

Para aplicação da metodologia foram desenvolvidos algoritmos em linguagem C/C++, através do ambiente de desenvolvimento Microsoft Visual Studio 6.0, para a segmentação de nódulos para a Base II e ainda, para a extração das medidas de textura e geometria. A biblioteca DCMTK (OFFIS, 1996) foi utilizada para manipulação das imagens DICOM.

O software *Bebúi* foi utilizado para a leitura de imagens DICOM provenientes da Base II e para a segmentação de nódulos para a Base I.

A biblioteca LIBSVM (CHANG e LIN, 2009) foi utilizada para os classificadores MVS. Esta biblioteca bem como a DCMTK encontram-se disponíveis gratuitamente na internet.

Os computadores utilizados para os testes foi um AMD Sempron 1,8 GHz, com 512 MB de memória RAM e HD com 80 GB e INTEL Core 2 Duo 2,4 GHz, com 2 GB de memória RAM e HD de 250 GB.

4 TESTES E RESULTADOS

Nesta seção, descrevem-se e discutem-se os resultados obtidos pela metodologia proposta para a classificação de nódulos pulmonares como benignos e malignos. São mostrados os resultados obtidos em cada abordagem de extração de características exposta no capítulo anterior e aplicada a cada base de dados adquirida.

A metodologia foi testada para as duas bases de dados adquiridas. A partir dos nódulos segmentados, obtiveram-se 39 casos de nódulos para a Base I e 198 casos de nódulos para a Base II. O objetivo com a aquisição de duas bases é avaliar a capacidade de generalização da metodologia aplicada em diferentes formas de aquisição.

Para cada base de dados, aplicaram-se as abordagens de extração de características relatadas na Seção 3.3. Após a extração de características nas abordagens, foi efetuada a divisão das amostras segundo os conjuntos de treinamento/teste (Tr/Te) conforme apresentados anteriormente na Tabela 1. Essa técnica de validação foi escolhida buscando-se aplicar um procedimento que englobasse as duas bases de dados em virtude da quantidade de casos de cada base. A técnica *leave-one-out* ou deixa um de fora não pode ser utilizada neste trabalho devido a quantidade de experimento a serem realizados em cada base de dados onde demandaria bastante tempo de processamento.

Os conjuntos (Tr/Te) foram submetidos aos classificadores MVS tradicional e de uma classe para predição da classificação. Cada conjunto (Tr/Te) foi submetido aos classificadores em um procedimento de cinco repetições com processo de seleção dos casos nos grupos de treino e teste de forma aleatória. Vale ressaltar que o processo de seleção aleatória não garante que casos diferentes sejam selecionados em cada execução. Para o classificador MVS de uma classe, o treinamento é feito apenas com uma classe. Foi escolhida empiricamente para treinamento a sub-amostra com os nódulos malignos e que foi considerada como sendo a classe positiva. Os testes realizados neste classificador avaliaram ora a classe positiva ora a classe negativa (nódulos benignos).

As métricas de validação apresentadas são sensibilidade, especificidade e acurácia. Estas são computadas através do cálculo das médias dos resultados obtidos por cada métrica em cada execução em um dado conjunto Tr/Te em uma determinada análise. Pretende-se, dessa forma, tornar a metodologia menos dependente o possível da seleção de casos “ótimos” para etapa de classificação. Nas próximas subseções são apresentados os resultados obtidos em cada experimento para as formas de extração de características propostas.

4.1 Testes usando Geometria

Nesta seção, são relatados os testes realizados com as bases de dados I e II submetidas aos classificadores MVS tradicional e MVS de uma classe. Nesses de testes, utilizaram-se apenas as características de geometria para descrever os nódulos a serem classificados. O vetor de características, portanto, foi formado pelos valores de esfericidade, desproporção esférica e densidade esférica de cada nódulo. Os resultados apresentados são mostrados de acordo com a base de dados e o classificador utilizado.

As Tabelas 2 e 3 descrevem os testes realizados com as medidas de geometria extraídas e submetidas ao classificador MVS tradicional.

Tabela 2 - Resultados dos testes usando geometria extraída da Base I e classificada pela MVS tradicional.

Base I			
Tr/Te	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
30/70	11,43	97,14	75,71
40/60	23,33	91,11	74,17
50/50	56,00	81,33	75,00
60/40	65,00	88,33	82,50
70/30	53,33	86,67	78,33
80/20	40,00	90,00	77,50

Tabela 3 - Resultados dos testes usando geometria extraída da Base II e classificada pela MVS tradicional.

Base II			
Tr/Te	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
30/70	66,86	78,57	72,71
40/60	75,33	70,33	72,83
50/50	76,80	69,20	73,00
60/40	73,50	77,00	75,25
70/30	76,67	83,33	80,00
80/20	70,00	75,00	72,50

De acordo com a Tabela 2, observa-se que para a Base I, o conjunto 60/40 apresentou o melhor resultado para acurácia com 82,5%, uma baixa sensibilidade com valor de 65% e especificidade de 88,33%. Ainda de acordo com a Tabela 2, observa-se que melhores valores de especificidade foram obtidos nos grupos 30/70 e 40/60, com valores de 97,14% e 91,11% respectivamente. Para esta base de dados, as medidas de geometria apresentaram-se com bom resultado na caracterização de nódulos benignos. Acredita-se que o baixo desempenho do classificador na sensibilidade está relacionado ao número reduzido de casos na amostra.

Segundo a Tabela 3, o melhor resultado obtido pelo conjunto Tr/Te para a Base II está no conjunto 70/30 onde se verifica que houve balanceamento entre os valores de sensibilidade (76,67%), especificidade (83,33%) e acurácia de 80%.

Observa-se que o classificador MVS tradicional conseguiu resultados melhores quando os conjuntos Tr/Te apresentam proporções de treinamento maiores que as proporções de teste em ambas as bases de dados.

As tabelas 4 e 5 apresentam os resultados obtidos com o uso das medidas geométricas avaliadas pelo classificador MVS de uma classe.

Tabela 4 - Resultados dos testes usando geometria extraída da Base I e classificada pela MVS de uma classe.

Base I			
Tr/Te	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
30/70	0,00	100,00	50,00
40/60	26,66	93,33	60,00
50/50	48,00	78,00	63,00
60/40	0,00	100,00	50,00
70/30	80,00	72,67	76,33
80/20	0,00	100,00	50,00

Tabela 5 - Resultados dos testes usando geometria extraída da Base II e classificada pela MVS de uma classe.

Base II			
Tr/Te	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
30/70	23,71	82,02	52,87
40/60	25,67	83,23	54,45
50/50	62,40	50,10	56,25
60/40	59,00	50,71	54,85
70/30	71,33	52,93	62,13
80/20	64,00	63,64	63,82

A Tabela 4 mostra os resultados obtidos para a Base I, pode-se identificar que o melhor resultado está no conjunto 70/30 onde a sensibilidade encontrada foi de 80% com uma especificidade de 72,67% e acurácia igual a 76,33%. Os baixos resultados de sensibilidade apresentados nos demais conjuntos indicam que o classificador não consegue prever a respeito da classe positiva que foi treinada, contudo ele desempenha boa avaliação na predição da classe negativa. Pode-se atribuir essa ocorrência à sensibilidade no ajuste dos parâmetros ρ e γ que são determinantes para a construção da região de separação entre a classe que se treina e a que se testa. Percebe-se ainda que o classificador apresenta dependência dos casos escolhidos tanto para o treino como para o teste. Ressalta-se que a base em questão apresenta poucos casos de nódulos malignos, fato que pode dificultar o aprendizado do classificador.

Na Tabela 5, verifica-se que o conjunto 80/20 demonstrou maior estabilidade na classificação, os valores de sensibilidade de 64%,

especificidade de 63,64% e acurácia de 63,82% comprovam a afirmativa. Contudo, para a Base II, o classificador não desempenhou um bom papel para a tarefa de classificação, o que conduz a conclusão que as medidas de geometrias apresentadas não foram significativas para a discriminação entre as classes propostas.

4.2 Testes usando Textura

Nesta seção, expõem-se os resultados encontrados para o uso do Índice de Simpson como medida de textura. A extração do Índice de Simpson ocorreu de acordo com as abordagens proposta na Seção 3.3.1. Cada abordagem, esfera ou anel, gerou regiões de análise que foram submetidas aos dois classificadores utilizados. Nas análises das regiões, incluiu-se outro experimento que considera todas as regiões analisadas em conjunto, esse experimento é rotulado de “TODOS”. O processo de treinamento, avaliação dos resultados e repetição de execuções é o mesmo aplicado as medidas de geometria. Os resultados são descritos a seguir em cada abordagem.

4.2.1 Análise em Anéis

Nesta seção estão descritos os resultados obtidos com a abordagem em questão para as duas bases de dados ordenados pelo uso do classificador. Primeiramente, a MVS tradicional e depois a MVS de uma classe.

As Tabelas 6, 7, 8, 9, 10 e 11 descrevem os testes realizados na abordagem de anéis para a Base I e Base II nos conjuntos de treinamento e testes propostos.

Tabela 6 - Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 30/70.

		30/70		
Análise		Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1	11,43	95,24	74,29
	A2	5,71	97,14	74,29
	A3	2,86	100,00	75,71
	A4	8,57	93,33	72,14
	A5	5,71	94,29	72,14
	TODOS	8,57	92,38	71,43
BASE II	A1	93,43	54,86	74,14
	A2	68,57	74,00	71,29
	A3	56,29	80,86	68,57
	A4	58,57	84,29	71,43
	A5	60,57	78,86	69,71
	TODOS	84,86	62,29	73,57

De acordo com a Tabela 6, percebe-se que a medida de textura extraída seguindo essa abordagem na Base I apresenta grande poder de representação de nódulos benignos, pois os valores obtidos para especificidade estão no intervalo bastante promissor de 92% a 100%. Contudo os resultados obtidos de sensibilidade, no intervalo de 2% e 11%, deixam a desejar para a discriminação de nódulos malignos. A análise que apresentou melhor resultado foi a A1, com valores de sensibilidade de 11,43%, especificidade de 95,24% e acurácia de 74,29%. Entende-se como análise de melhor resultado o experimento que apresentar melhor balanceamento entre os valores de sensibilidade, especificidade e acurácia. Na ausência deste balanceamento, considera-se como melhor análise o experimento que apresenta maiores valores de sensibilidade, seguida dos melhores resultados obtida para acurácia. Isso porque se acredita que seja melhor informar sobre um diagnóstico de malignidade e despertar a partir desse diagnóstico uma atenção maior para o nódulo em estudo por parte do especialista.

Para a Base II, a Tabela 6 demonstra que a análise A1 também apresentou melhores resultados com sensibilidade de 93,43%, especificidade de 54,86% e acurácia de 74,14%. Embora o valor de especificidade tenha sido baixo nesta análise, verifica-se que as demais análises apresentaram

desempenho melhor sendo que apenas na análise “TODOS” o resultado foi baixo devido a forte influência da análise A1.

Tabela 7 - Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 40/60.

		40/60			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		13,33	91,11	71,67
	A2		13,33	80,00	63,33
	A3		3,33	91,11	69,17
	A4		16,67	88,89	70,83
	A5		6,67	95,56	73,33
	TODOS		6,67	95,56	73,33
BASE II	A1		76,00	69,67	69,67
	A2		64,00	89,33	76,67
	A3		63,00	77,67	70,33
	A4		65,00	81,33	73,17
	A5		55,33	78,00	66,67
	TODOS		80,00	65,00	72,50

Na Tabela 7, a análise com melhor resultado para o conjunto 40/60 na Base I foi a análise A4 com valores de 16,67% de sensibilidade, 88,89% de especificidade e acurácia de 70,83%. Observa-se que em outras análises foram encontrados maiores valores para especificidade. Percebe-se ainda que ao juntar as análises A1, A2, A3, A4 e A5 para formar o experimento “TODOS”, a análise A5 teve predominância em relação às demais, pois os valores obtidos na análise “TODOS” foram idênticos aos resultados da análise A5.

Para a Base II, o melhor resultado obtido foi conseguido com a análise “TODOS”, onde o valor de sensibilidade encontrado foi de 80%, com especificidade de 65% e acurácia de 72,5%. Assim como na Base I, valores maiores de especificidade foram obtidos em outras análises individuais, contudo a união delas comprometeu os resultados desta medida.

A Tabela 8 descreve os resultados para o conjunto 50/50, onde se encontrou na análise A1 da Base I, o melhor resultado deste conjunto com os valores de sensibilidade de 20%, especificidade de 94,67% e acurácia de 76%. As baixas sensibilidades encontradas nas análises conduzem a conclusão de que o Índice de Simpson calculado manteve-se com valores muito próximos para os nódulos benignos assim como os malignos, o que dificultou ao

classificador estabelecer um bom treinamento e assim diferenciar as classes nos grupos de teste. Na Base II, a análise A1 ficou com um valor baixo de sensibilidade de 86%, no entanto a especificidade estava baixa com o valor de 59,2%. A acurácia para essa análise foi de 72,6%. Percebe-se que as análises alternam no ganho de percentuais entre as medidas de sensibilidade e especificidade. Quando em uma análise, o valor de sensibilidade aumenta o valor da especificidade diminui o que pode caracterizar uma homogeneidade, nas análises, para os valores do Índice de Simpson e isto prejudica a discriminação.

Tabela 8 - Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificada pela MVS tradicional com configuração 50/50.

		50/50			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		20,00	94,67	76,00
	A2		0,00	96,00	72,63
	A3		16,00	86,67	69,00
	A4		0,00	100,00	75,00
	A5		0,00	100,00	75,00
	TODOS		12,00	89,33	70,00
BASE II	A1		86,00	59,20	72,60
	A2		66,80	86,40	76,60
	A3		60,80	77,60	69,20
	A4		69,20	78,40	73,80
	A5		61,20	79,20	70,20
	TODOS		80,00	60,40	70,20

Na Tabela 9, para a Base I, a análise A4 foi apontada como melhor análise para o conjunto 60/40 devido aos valores obtidos para sensibilidade (15%), especificidade (93,33%) e acurácia de 73,75%. Porém, acredita-se que os baixos valores obtidos nas sensibilidades são decorrentes da divisão dos conjuntos de Tr/Te uma vez que a Base I é carente em termos de casos para amostra. Assim, quanto mais casos de nódulos malignos incluídos no grupo de treino, menos casos se têm para o grupo de teste o que eleva as taxas de erros e reduz bruscamente os valores de sensibilidade conforme tem sido apresentando.

Na Base II, a análise A1 apresentou-se com melhores resultados com os valores de sensibilidade de 76%, especificidade de 69% e acurácia 72,5%.

Contudo, identificou-se que em outras análises foram obtidos valores maiores de especificidade como na análise A2 que apresentou um resultado de especificidade de 88,5%.

Tabela 9 - Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 60/40.

		60/40			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		5,00	91,67	70,00
	A2		5,00	91,67	70,00
	A3		10,00	95,00	73,75
	A4		15,00	93,33	73,75
	A5		5,00	90,00	68,75
	TODOS		5,00	93,33	71,25
BASE II	A1		76,00	69,00	72,50
	A2		65,00	88,50	76,75
	A3		58,50	75,50	67,00
	A4		67,00	79,50	73,25
	A5		55,50	87,00	71,25
	TODOS		74,50	67,00	70,75

A Tabela 10 mostra os resultados obtidos para o conjunto 70/30, onde se nota que na análise “TODOS” da Base I, o valor de sensibilidade igual a zero obtido é decorrente da interferência significativa da análise A2 na fase de treinamento. Considerando todos experimentos, a análise mais representativa foi a A3 com sensibilidade de 20%, especificidade de 93,33% e acurácia de 75%. Sendo que essa medida de sensibilidade bem com as demais encontradas nas outras análises indica que o classificador não foi eficiente para a discriminação, isto pode estar relacionado com o grupo de treinamento submetido para seu aprendizado e ainda com as medidas de texturas que não foram representativas suficientemente. Com relação aos resultados obtidos na Base II, a análise A1 destacou-se como melhor representativa devido aos seus valores de sensibilidade de 95,33%, especificidade de 58,67% e acurácia de 77%. Novamente, percebe-se que o ganho percentual em uma métrica implica na baixa de outra, o que justifica a afirmativa feita anteriormente sobre similaridade dos valores do Índice de Simpson para as duas classes: benignos e malignos na qual essa similaridade conduz a uma etapa ruim de aprendizagem do classificador.

Tabela 10 - Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 70/30.

		70/30			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		20,00	86,67	70,00
	A2		0,00	97,78	73,33
	A3		20,00	93,33	75,00
	A4		6,67	93,33	71,67
	A5		13,33	93,33	73,33
	TODOS		0,00	91,11	68,33
BASE II	A1		95,33	58,67	77,00
	A2		62,00	87,33	74,67
	A3		60,00	82,67	71,33
	A4		64,67	80,67	72,67
	A5		57,33	81,33	69,33
	TODOS		84,00	62,00	73,00

Tabela 11 - Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 80/20.

		80/20			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		20,00	86,67	70,00
	A2		0,00	100,00	75,00
	A3		40,00	83,33	72,50
	A4		10,00	93,33	72,50
	A5		0,00	90,00	67,50
	TODOS		0,00	93,33	70,00
BASE II	A1		96,00	52,00	74,00
	A2		67,00	86,00	76,50
	A3		68,00	81,00	74,50
	A4		68,00	84,00	76,00
	A5		54,00	81,00	67,50
	TODOS		81,00	66,00	73,50

Para a Tabela 11, o conjunto 80/20 conseguiu melhores resultados com a análise A3 na Base I, onde a sensibilidade apresentou seu maior valor - 40% - encontrado entre todos os conjuntos aplicados nessa base. Acredita-se que o classificador obteve, durante a etapa de treinamento, casos malignos que possibilitaram maior discriminação. Contudo fica notável, para os testes realizados na Base I que o classificador dependente das seleções de casos, principalmente, dos casos malignos para que se possa realizar bom treinamento e conseqüentemente boa classificação. Na Base II, a análise A1

teve destaque com valor de sensibilidade de 96%. Contudo as medidas de especificidade de 52% e acurácia de 74% foram menores que outras encontradas nas demais análises como, por exemplo, na análise A2, onde se teve especificidade de 86% e acurácia de 76,5%.

As Tabelas 12, 13, 14, 15, 16 e 17 descrevem os testes realizados na abordagem de anéis para a Base I e Base II nos conjuntos de treinamento e testes propostos. Nestes testes o classificador utilizado foi a MVS de uma classe.

Os resultados apresentados na Tabela 12 mostram que na Base I, a análise que obteve melhor desempenho foi a A4, com sensibilidade de 28,57%, especificidade de 75,33% e acurácia de 51,95%. Em algumas análises obtiveram-se valores muitos bons para a especificidade, contudo a baixa sensibilidade encontrada referentes a essas análises – inferiores ao valor encontrado na análise A4 - fez com que se descartassem tais análises. Percebe-se então, que o Índice de Simpson configura-se como bom discriminante de nódulos benigno, como constatado, anteriormente, nos testes realizados com o outro classificador.

Para a Base II, a análise que se destacou foi a “TODOS” onde se encontrou um melhor balanceamento entre as medidas de sensibilidade, especificidade e acurácia. O valor obtido para a sensibilidade foi de 74,29%, com especificidade de 77,17% e acurácia de 75,73%. Vale ressaltar que a análise A2 influenciou significativamente a análise de melhor resultado uma vez que se observa que os resultados obtidos estão próximos ao encontrados na análise “TODOS”.

Tabela 12 - Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 30/70.

		30/70			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		0,00	100,00	50,00
	A2		0,00	100,00	50,00
	A3		0,00	100,00	50,00
	A4		28,57	75,33	51,95
	A5		20,00	33,33	26,67
	TODOS		8,57	94,67	51,62
BASE II	A1		41,71	95,35	68,53
	A2		74,29	75,35	74,82
	A3		79,43	30,51	54,97
	A4		91,14	15,96	53,55
	A5		9,14	96,77	52,96
	TODOS		74,29	77,17	75,73

Na Tabela 13, para a Base I, o melhor resultado obtido está na análise “TODOS” onde a sensibilidade foi igual a 46,67%, a especificidade igual a 81,33% e acurácia igual a 64%. Verifica-se que a análise A2 mantém forte influência nos resultados obtidos na melhor análise. Para a Base II, a análise “TODOS” também foi marcada como melhor discriminante. Os valores obtidos para sensibilidade, especificidade e acurácia foram 74%, 80,81% e 77,4%, respectivamente. Percebe-se que o classificador apresenta um melhor desempenho na avaliação da Base II. Este fato pode estar relacionado com a quantidade de casos que a amostra possui o que facilita ao classificador um melhor aprendizado da classe positiva (usada para o treino) que aqui consideramos como sendo os casos de nódulos malignos.

Tabela 13 - Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 40/60.

		40/60			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		0,00	100,00	50,00
	A2		33,33	81,33	57,33
	A3		0,00	100,00	50,00
	A4		6,67	90,67	48,67
	A5		20,00	82,00	51,00
	TODOS		46,67	81,33	64,00
BASE II	A1		73,67	69,49	71,58
	A2		79,00	41,01	60,01
	A3		64,67	72,93	68,80
	A4		41,67	88,89	65,28
	A5		61,00	78,18	69,59
	TODOS		74,00	80,81	77,40

Tabela 14 - Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 50/50.

		50/50			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		60,00	77,33	68,67
	A2		40,00	76,67	58,33
	A3		48,00	74,00	61,00
	A4		28,00	81,33	54,67
	A5		56,00	52,00	54,00
	TODOS		16,00	100,00	58,00
BASE II	A1		60,80	86,26	73,53
	A2		40,00	70,51	55,25
	A3		48,40	70,10	59,25
	A4		80,00	46,46	63,23
	A5		50,40	60,20	55,30
	TODOS		86,40	62,63	74,51

Os resultados apresentados na Tabela 14 são para os experimentos com conjunto 50/50. Verifica-se que para a Base I a análise que obteve maior poder discriminatório foi a A1. Nela encontrou-se sensibilidade de 60%, especificidade de 77,33% e acurácia de 68,67%. Embora o classificador não tenha alcançado predições satisfatórias, nota-se, no entanto, que os resultados das medidas estão mais balanceados. Isso pode ser justificado pelo ajuste de parâmetros conseguidos pelo estimador. Para a Base II, a análise “TODOS” apresentou uma boa sensibilidade com valor de 86,4%, com especificidade de 62,63% e acurácia de 74,51%. Pode-se observar ainda que nesta base, as

medidas de sensibilidade e especificidade mantêm uma relação de efeito reverso, onde o aumento de uma implica na queda da outra.

Tabela 15 - Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 60/40.

		60/40			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		20,00	82,00	51,00
	A2		50,00	75,33	62,67
	A3		55,00	84,67	69,83
	A4		15,00	86,00	50,50
	A5		70,00	33,33	51,67
	TODOS		40,00	70,00	55,00
BASE II	A1		46,50	95,15	70,83
	A2		28,00	94,34	61,17
	A3		84,50	49,29	66,90
	A4		78,50	77,17	77,84
	A5		35,50	75,96	55,73
	TODOS		62,00	72,93	67,46

Na Tabela 15, a análise A5 obteve o melhor resultado de sensibilidade, com 70%, em relação às demais, contudo a baixa especificidade de 33,33%, a menor entre todas as outras, impediu que esta análise fosse apontada como melhor discriminante. Sendo assim, a análise A3 destacou-se no quesito balanceamentos das medidas e obteve sensibilidade de 55%, especificidade de 84,67% e acurácia de 69,83%. Na Base II, a análise que apresentou melhores resultados para o conjunto 60/40 foi a análise A4 que obteve valor de sensibilidade de 78,5%, especificidade de 77,17% e acurácia de 77,84%. Destaca-se, mais uma vez, que o classificador tem alcançado maior estabilidade na Base II em virtude da quantidade de casos da amostra.

A Tabela 16 mostra os resultados para o conjunto 70/30. Na Base I, a análise A3 obteve sensibilidade de 53,33%, especificidade de 76% e acurácia de 64,67%. Esta análise foi ainda a variável que mais influenciou nos resultados obtidos pela análise "TODOS". Destaca-se que outras análises obtiveram valores melhores e até razoáveis de especificidade com a análise A1 que conseguiu 86%. Para a Base II, o melhor resultado encontrado está na análise A4 que conseguiu balancear os valores de sensibilidade, especificidade e acurácia. Foram encontrados valores de 78% para a sensibilidade, 79,19%

para especificidade e 78,6% para a acurácia. Com resultados apresentadas nesta tabela, pode-se concluir que os altos valores de especificidade continuam apontando o Índice de Simpson como bom discriminador de casos de nódulos benignos.

Tabela 16 - Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 70/30.

		70/30			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		40,00	86,00	63,00
	A2		46,67	81,33	64,00
	A3		53,33	76,00	64,67
	A4		20,00	68,67	44,33
	A5		20,00	76,67	48,33
	TODOS		53,33	73,33	63,33
BASE II	A1		40,00	95,56	67,78
	A2		60,67	89,29	74,98
	A3		66,00	57,17	61,59
	A4		78,00	79,19	78,60
	A5		34,00	88,48	61,24
	TODOS		74,67	79,60	77,13

Tabela 17 - Resultados dos testes usando textura, em anéis, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 80/20.

		80/20			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		70,00	88,00	79,00
	A2		50,00	71,33	60,67
	A3		20,00	81,33	50,67
	A4		40,00	82,00	61,00
	A5		10,00	68,67	39,33
	TODOS		50,00	70,00	60,00
BASE II	A1		63,00	79,39	71,20
	A2		56,00	90,91	73,45
	A3		41,00	84,85	62,92
	A4		53,00	74,95	63,97
	A5		70,00	45,25	57,63
	TODOS		66,00	90,51	78,25

Na Tabela 17, são descritos os resultados dos experimentos realizados para o conjunto Tr/Te de 80/20. Na Base I, os percentuais de 70, 88 e 79 correspondem aos valores de sensibilidade, especificidade e acurácia

encontrados na análise A1 onde se obteve o melhor balanceamento e maior discriminação entre as classes. Na Base II, a análise de destaque foi “TODOS” onde se obteve sensibilidade de 66%, especificidade de 90,51% e acurácia de 78,25%.

4.2.2 Análise em Esferas

Nesta seção, estão descritos os resultados obtidos na abordagem em esferas, aplicadas nas duas bases de dados e submetidas aos classificadores MVS tradicional e MVS de uma classe.

As Tabelas 18, 19, 20, 21, 22 e 23 descrevem os experimentos realizados com o uso do classificador MVS tradicional considerando os conjuntos de treinamento e testes apresentados na Tabela 1. Os resultados mostrados são para as bases I e II.

Tabela 18 - Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 30/70.

		30/70		
		Sensibilidade (%)	Especificidade (%)	Acurácia (%)
	Análise			
BASE I	R1	0,00	98,10	73,57
	R2	8,57	96,19	74,29
	R3	17,14	86,67	69,29
	R4	0,00	100,00	75,00
	R5	10,00	83,33	65,00
	R6	11,43	96,19	75,00
	TODOS	22,86	90,48	73,57
BASE II	R1	57,71	91,14	74,43
	R2	76,29	70,00	73,14
	R3	67,14	85,43	76,29
	R4	51,43	80,29	65,86
	R5	60,86	70,29	65,57
	R6	50,57	74,00	62,29
	TODOS	68,00	78,86	73,43

Na Tabela 18, são mostrados os resultados dos experimentos realizados com o conjunto Tr/Te de configuração 30/70. A análise “TODOS” se destacou por conseguir uma sensibilidade de 22,86%, a maior entre todas as análises, uma especificidade de 90,48% e acuraria de 73,57%. Acredita-se,

mais uma vez, que os baixos valores de sensibilidades encontrados estão relacionados com a pouca quantidade de casos encontrados na Base I. Dessa forma, o classificador não consegue aprender o suficiente para efetuar uma boa predição. Para a Base II, percebe-se um melhor balanceamento entre os valores de sensibilidade, especificidade e acurácia. Nesta base, a análise R2 conseguiu melhor discriminação, considerando o balanceamento pretendido. Nessa análise, o valor de sensibilidade, especificidade e acurácia foram de 86%, 60,33% e 73,17% respectivamente.

Tabela 19 - Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 40/60.

		40/60			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		0,00	97,78	73,33
	R2		13,33	90,00	70,83
	R3		10,00	90,00	70,00
	R4		26,67	80,00	66,67
	R5		40,00	80,00	70,00
	R6		20,00	94,44	75,83
	TODOS		40,00	82,22	71,67
BASE II	R1		58,33	93,00	75,67
	R2		86,00	60,33	73,17
	R3		69,00	87,00	78,00
	R4		57,00	78,67	67,83
	R5		55,67	79,00	67,33
	R6		64,67	62,67	63,67
	TODOS		68,00	80,33	74,17

A Tabela 19 apresenta os resultados obtidos para os experimentos realizados para o conjunto Tr/Te de 40/60. Novamente, a análise “TODOS” demonstrou melhor desempenho na discriminação. Com sensibilidade de 40%, especificidade de 82,22% e acurácia de 71,67% essa análise parece ter recebido forte influência da análise R5, onde se verifica valores muito próximos para as medidas. Percebe-se ainda, que essa outra abordagem continua a revelar o Índice de Simpson como sendo uma medida boa para discriminar nódulos benignos, isto pode ser observado pelos altos valores de especificidades encontrados nas demais análises. Para a Base II, a análise R2 foi apontada como melhor discriminante. Essa análise obteve sensibilidade de

86%, especificidade de 60,33% e acurácia de 73,17%. Ressalta-se que essa análise foi escolhida em razão dos critérios definidos anteriormente. Busca-se um melhor balanceamento entre as medidas de sensibilidade, especificidade e acurácia e em seguida o maior resultado obtido nas sensibilidades, dessa forma, damos ênfase para os resultados que apontam um acerto de casos de nódulos malignos. Numa outra visão, a análise R3 pode ser considerada como boa na discriminação onde se observa que houve uma queda na sensibilidade (69%) e ganho na especificidade (87%) e acurácia (78%), sendo esta última a maior encontrada entre todas as análises e ainda que o balanceamento entre as medidas foi mantido.

Tabela 20 - Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 50/50.

		50/50		
		Sensibilidade (%)	Especificidade (%)	Acurácia (%)
	Análise			
BASE I	R1	24,00	86,67	71,00
	R2	0,00	100,00	75,00
	R3	0,00	100,00	75,00
	R4	24,00	88,00	72,00
	R5	40,00	86,67	75,00
	R6	24,00	89,33	73,00
	TODOS	28,00	89,33	74,00
BASE II	R1	56,00	92,00	74,00
	R2	68,00	76,00	72,00
	R3	64,40	86,80	75,60
	R4	60,00	73,60	66,80
	R5	67,20	64,00	65,60
	R6	54,00	78,40	66,20
	TODOS	61,60	90,40	76,00

Na Tabela 20, o melhor resultado encontrado na Base I foi na análise R5, considerando o conjunto Tr/Te de 50/50. A sensibilidade encontrada nessa análise foi de 40%, a especificidade foi de 86,67% e acurácia de 75%. Observa-se que em algumas análises foram encontradas sensibilidades iguais a zero. Novamente, acredita-se que a quantidade de casos da base é a causa do baixo desempenho do classificador. Para a Base II, a análise considerada mais representativa foi R2 que conseguiu sensibilidade de 68%, especificidade de 76% e acurácia de 72% de acordo com o balanceamento buscado. Vale ressaltar que outras análises conseguiram resultados melhores para

especificidade como a análise R1 que obteve o valor de especificidade igual a 92%.

Tabela 21 - Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 60/40.

		60/40			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		20,00	90,00	72,50
	R2		10,00	95,00	73,75
	R3		5,00	91,67	70,00
	R4		10,00	85,00	66,25
	R5		45,00	86,67	76,25
	R6		20,00	96,67	77,50
	TODOS		45,00	80,00	71,25
BASE II	R1		60,00	93,50	76,75
	R2		84,50	60,50	72,50
	R3		68,00	88,50	78,25
	R4		62,50	75,50	69,00
	R5		56,00	74,00	65,00
	R6		55,50	79,50	67,50
	TODOS		64,50	81,00	72,75

A Tabela 21 mostra os resultados obtidos para o conjunto Tr/Te de 60/40. Na Base I, destacou-se a análise R5 que conseguiu sensibilidade igual a 45%, especificidade igual a 86,67% e acurácia igual a 76,25%. Verifica-se ainda que essa análise é a que mais influencia nos resultados obtidos na análise "TODOS". Acredita-se que, além do problema de poucos casos na amostra, o conjunto Tr/Te também causa grande impacto na etapa de aprendizagem do classificador tornando a escolha dos grupos de treino e teste um fator importante. Essa possibilidade conduz a conclusão de que o classificador é dependente das amostras escolhidas para o treinamento e assim realizar uma boa aprendizagem e conseqüentemente, uma boa predição. Para a Base II, a análise R2 foi que obteve maior discriminação, com sensibilidade de 84,5%, especificidade de 60,5% e acurácia de 72,5%. Destaca-se ainda a análise R3, enquadra-se nos critérios de balanceamento antes mencionados, que obteve melhores valores de especificidade (88,5%) e acurácia (78,25%), a máxima acurácia entre todas as análises. Verifica-se ainda que a maior especificidade foi encontrada na análise R1 com o valor de 93,5%.

Tabela 22 - Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 70/30.

		70/30		
Análise		Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1	6,67	93,33	71,67
	R2	6,67	91,11	70,00
	R3	0,00	100,00	75,00
	R4	26,67	91,11	75,00
	R5	26,67	91,11	75,00
	R6	26,67	91,11	75,00
	TODOS	40,00	88,89	76,67
BASE II	R1	58,67	93,33	76,00
	R2	92,67	49,33	71,00
	R3	67,33	83,33	75,33
	R4	61,33	80,67	71,00
	R5	62,67	73,33	68,00
	R6	56,00	68,00	62,00
	TODOS	62,00	79,33	70,67

A Tabela 22 apresenta os resultados para o conjunto Tr/Te de configuração 70/30. Encontrou-se para a Base I a melhor discriminação na análise “TODOS” com sensibilidade de 40%, a maior encontrada, especificidade de 88,89% e acurácia de 76,67%. Observa-se que as análises R4, R5 e R6 apresentaram os mesmos resultados. Essa ocorrência leva a conclusão que os valores obtidos pelo Índice de Simpson em cada análise permaneceram, na média, similar entre todas, sinalizando que as análises mencionadas não apresentaram nenhuma variação de diversidade. Para a Base II, a análise R3 apresentou a melhor discriminação, com a sensibilidade de 67,33%, especificidade de 83,33% e acurácia de 75,33%. Percebe-se ainda que a análise R2 obteve a máxima sensibilidade entre todas as análises com valor igual a 92,67% e que a análise R1 encontrou a máxima especificidade entre todas as análises com valor igual a 93,33%.

Na Tabela 23, são mostrados os resultados dos experimentos realizados para o conjunto Tr/Te de 80/20. A Base I teve como análise de maior representatividade a análise R5 onde se encontrou a melhor predição de todos os experimentos realizados nessa abordagem usando o classificador MVS tradicional. Acredita-se que nesses resultados, o classificador possa ter encontrado os grupos de treino e teste que melhor diferenciam as classes. Na análise R5, a sensibilidade foi de 70%, a especificidade foi de 100% e acurácia

de 92,5%. Para a Base II, a análise R2 destacou-se como melhor discriminante onde se obteve uma boa sensibilidade de 91%, uma baixa especificidade de 57% e uma acurácia de 74%. Nesse conjunto Tr/Te, percebe-se que o classificador apresentou desempenho instável, conduzindo as predições de sensibilidade e especificidade a um efeito reverso, onde o aumento de uma implica na baixa da outra.

Tabela 23 - Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS tradicional com configuração 80/20.

		80/20		
		Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	Análise			
	R1	0,00	100,00	75,00
	R2	0,00	100,00	75,00
	R3	0,00	100,00	75,00
	R4	10,00	83,33	65,00
	R5	70,00	100,00	92,50
	R6	60,00	86,67	80,00
	TODOS	40,00	80,00	70,00
BASE II	R1	59,00	97,00	78,00
	R2	91,00	57,00	74,00
	R3	55,00	90,00	72,50
	R4	37,00	85,00	61,00
	R5	55,00	69,00	62,00
	R6	57,00	74,00	65,50
		TODOS	64,00	90,00

As Tabelas 24, 25, 26, 27, 28 e 29 descrevem os experimentos realizados com o uso do classificador MVS de uma classe considerando os conjuntos Tr/Te propostos na Tabela 1. Os resultados mostrados contemplam as bases I e II.

A Tabela 24 apresenta os resultados para os experimentos com o conjunto Tr/Te de 30/70. A análise R3 demonstrou melhor desempenho para a discriminação, pois obteve o melhor balanceamento entre as medidas de sensibilidade, especificidade e acurácia com os seguintes percentuais: 51,43% para sensibilidade, 82,67% para especificidade e 67,05% para acurácia. Em várias análises, obtiveram-se valores iguais a zero para sensibilidade ou para especificidade. Acredita-se que os fatores que conduziram a esta ocorrência estão relacionados, primeiramente com Índice de Simpson, que pode apresentar valores bastante similares para as classes (maligno e benigno) e

em seguida a estimativa de parâmetros para o classificador. Para a Base II, a análise que se destacou foi a R6 com sensibilidade de 88%, especificidade de 47,47% e acurácia de 67,74%.

Tabela 24 - Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 30/70.

		30/70			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		0,00	100,00	50,00
	R2		0,00	100,00	50,00
	R3		51,43	82,67	67,05
	R4		100,00	0,00	50,00
	R5		28,57	76,67	52,62
	R6		0,00	100,00	50,00
	TODOS		42,86	88,67	65,76
BASE II	R1		82,86	20,00	51,43
	R2		35,71	95,76	65,74
	R3		39,14	91,92	65,53
	R4		61,71	73,33	67,52
	R5		91,14	37,37	64,26
	R6		88,00	47,47	67,74
	TODOS		76,29	47,47	61,88

A Tabela 25 mostra que análise R4 foi a melhor discriminante na Base I para o conjunto Tr/Te de 40/60. Nessa análise, a sensibilidade encontrada foi de 96%, a especificidade foi de 10% e acurácia de 53%. Esse baixo desempenho do classificador, similar ao experimento anterior, reforça a afirmativa a respeito dos parâmetros estimados para o conjunto Tr/Te. Acredita-se ainda que a seleção de casos para a amostra de treinamento não está sendo representativa suficientemente para o classificador aprenda a distinguir as classes. Para a Base II, o melhor resultado obtido, considerando as medidas razoavelmente balanceadas entre si, está na análise “TODOS”, onde se conseguiu sensibilidade de 60,67%, especificidade de 73,54% e acurácia de 67,10%. Percebe-se que individualmente, outras análises na Base II obtiveram resultados melhores que análise “TODOS” como a análise R5 que obteve sensibilidade de 95,67% e a análise R2 que obteve especificidade de 89,9%.

Tabela 25 - Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 40/60.

		40/60			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		0,00	100,00	50,00
	R2		0,00	100,00	50,00
	R3		0,00	100,00	50,00
	R4		96,00	10,00	53,00
	R5		13,33	92,00	52,67
	R6		26,67	92,00	59,33
	TODOS		0,00	100,00	50,00
BASE II	R1		26,67	80,00	53,33
	R2		22,00	89,90	55,95
	R3		89,00	33,33	61,17
	R4		61,71	54,14	57,93
	R5		95,67	16,97	56,32
	R6		93,33	22,63	57,98
	TODOS		60,67	73,54	67,10

Tabela 26 - Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 50/50.

		50/50			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		0,00	100,00	50,00
	R2		64,00	68,67	66,33
	R3		0,00	100,00	50,00
	R4		28,00	90,67	59,33
	R5		44,00	70,67	57,33
	R6		56,00	72,67	64,33
	TODOS		0,00	100,00	50,00
BASE II	R1		50,80	59,80	55,30
	R2		54,80	93,94	74,37
	R3		67,20	74,95	71,07
	R4		78,80	55,96	67,38
	R5		72,80	45,45	59,13
	R6		93,60	45,45	69,53
	TODOS		76,40	58,38	67,39

Na Tabela 26, são mostrados os resultados encontrados para o experimento com o conjunto Tr/Te de 50/50. Na Base I, a análise R2 apresentou o melhor resultado. O valor de sensibilidade foi igual a 64%,

especificidade igual a 68,67% e acurácia igual a 66,33%. Nessa base de dados, verifica-se que o classificador é dependente da seleção das amostras para o treino e teste. Isto justifica a ocorrência de alguns percentuais zerados em várias análises. Para a Base II, devido ao desbalanceamento entre as medidas de sensibilidade, especificidade e acurácia, a análise R4 foi destacada como melhor discriminante devido aos resultados obtidos. Nela a sensibilidade foi de 78,8%, especificidade de 55,96% e acurácia de 67,38. Observa-se ainda que a análise “TODOS” está sobre bastante influência da análise R4 devido aos valores similares e chegando inclusive a apresentar especificidade e acurácia com valores maiores. Entretanto, conforme dito anteriormente tem-se interesse em destacar as análises com maiores acertos para os resultados de sensibilidade.

Tabela 27 - Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 60/40.

		60/40			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		90,00	76,00	83,00
	R2		75,00	68,67	71,83
	R3		40,00	87,33	63,67
	R4		75,00	67,33	71,17
	R5		35,00	78,67	56,83
	R6		30,00	84,67	57,33
	TODOS		75,00	84,00	79,50
BASE II	R1		46,50	60,00	53,25
	R2		40,50	94,75	67,62
	R3		72,00	52,12	62,06
	R4		72,00	51,31	61,66
	R5		89,00	56,97	72,98
	R6		79,00	55,15	67,08
	TODOS		76,00	70,30	73,15

A Tabela 27 mostra os experimentos realizados para o conjunto Tr/Te com configuração 70/30. Para a Base I, a análise R1 encontrou um valor bom de sensibilidade igual a 90%, a especificidade encontrada foi de 76% e acurácia igual a 83%. Acredita-se que nessa análise, o Índice de Simpson calculado conseguiu ser um bom discriminador para a classe de nódulos malignos e ainda que as amostras escolhidas para o treino do classificador, em média, foram boas representativas, garantindo um aprendizado bom. Para a

Base II, a análise que melhor discriminou foi “TODOS” com sensibilidade de 76%, especificidade de 70,3% e acurácia de 73,15%. Verifica-se ainda, que individualmente, outras regiões alcançaram melhores resultados para a sensibilidade e especificidade. Destaca-se a análise R5 que obteve sensibilidade de 89% e a análise R2 que obteve especificidade de 94,75%.

Tabela 28 - Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 70/30.

		70/30			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		86,67	76,00	81,33
	R2		73,33	84,67	79,00
	R3		26,67	80,00	53,33
	R4		33,33	84,67	59,00
	R5		60,00	78,67	69,33
	R6		53,33	68,67	61,00
	TODOS		60,00	86,67	73,33
BASE II	R1		60,67	75,56	68,11
	R2		55,33	86,46	70,90
	R3		66,00	76,57	71,28
	R4		80,67	64,65	72,66
	R5		92,67	46,67	69,67
	R6		96,67	36,97	66,82
	TODOS		66,00	77,37	71,69

Na Tabela 28, a análise R1, novamente, destaca-se como melhor discriminante entre as classes propostas. Percebe-se que o classificador realizou boa predição, mantendo o balanceamento entre as medidas de sensibilidade, especificidade e acurácia. Verifica-se ainda que o conjunto Tr/Te disponibiliza ao classificador um maior aprendizado resultando na seleção de casos que melhor discrimine entre as duas classes. A sensibilidade obtida foi de 86,67%, a especificidade foi de 76% e a acurácia foi de 81,33%. Para a Base II, a análise R4 encontrou sensibilidade de 80,67%, especificidade de 64,65% e acurácia de 72,66% que configuraram a melhor discriminação entre nódulos malignos e benignos com bom balanceamento entre as medidas. Observa-se que a análise “TODOS” também apresentou bom balanceamento entre as medidas e assim se configurando como segundo melhor resultado obtido e mais, percebe-se que ela está sobre forte influência da análise R3.

Tabela 29 - Resultados dos testes usando textura, em esferas, extraída da Base I e Base II, classificadas pela MVS de uma classe com configuração 80/20.

		80/20			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		40,00	90,00	65,00
	R2		40,00	90,00	65,00
	R3		40,00	73,33	56,67
	R4		10,00	92,67	51,33
	R5		50,00	13,33	31,67
	R6		10,00	99,33	54,67
	TODOS		70,00	85,33	77,67
BASE II	R1		39,00	60,00	49,50
	R2		63,00	93,94	78,47
	R3		76,00	84,85	80,42
	R4		50,00	75,76	62,88
	R5		91,00	46,67	68,83
	R6		75,00	50,71	62,85
	TODOS		76,00	85,86	80,93

A Tabela 29 mostra que na Base I, para o experimento com o conjunto 80/20, a análise “TODOS”, conseguiu o melhor resultado obtendo sensibilidade de 70%, especificidade de 85,33% e acurácia de 77,67%. Os valores individuais de sensibilidade foram baixos em todas as outras análises, somente reunindo estas análises conseguiu-se a sensibilidade mencionada. Por outro lado, as demais análises produziram valores de especificidade bem maiores que a análise “TODOS” chegando a satisfatório resultado de 99,33% como no caso da análise R6. Para a Base II, a análise “TODOS” também foi apontando como melhor discriminante obtendo sensibilidade de 76%, especificidade de 85,86% e acurácia de 80,93%. Verifica-se ainda que a análise R3 contribuiu significativamente nos resultados obtidos pela análise “TODOS”.

4.3 Testes usando Textura e Geometria

Nesta seção, são mostrados os resultados encontrados para o uso do Índice de Simpson em conjunto com as medidas de geometria utilizadas nesse trabalho. A extração do Índice de Simpson ocorreu de maneira similar à apresentada na seção anterior, isto é, consideram-se as abordagens de anéis e

esferas para cálculo da medida de textura dos nódulos. Em seguida, os valores do Índice de Simpson obtidos são juntados com as medidas geométricas. Além das análises propostas, incluiu-se novamente outro experimento que considera todas as regiões analisadas em conjunto que foi nomeado de “TODOS”. O processo de treinamento, avaliação dos resultados e repetição de execuções é o mesmo aplicado as medidas de geometria. Os experimentos também são realizados para os dois classificadores usados na metodologia. Os resultados são descritos a seguir em cada abordagem.

4.3.1 Textura em Anéis e Geometria

Nesta seção estão descritos os resultados obtidos com a abordagem em anéis para cálculo do Índice de Simpson apresentado na Equação 3 (Seção 2.6.1.1) juntamente com as medidas de geometria propostas na seção 2.6.2. Essa abordagem objetiva avaliar se houve melhoria no desempenho dos classificadores.

As Tabelas 30, 31, 32, 33, 34 e 35 descrevem os experimentos realizados dessa abordagem aplicados à Base I e Base II nos conjuntos Tr/Te propostos e submetidos ao classificador MVS tradicional.

A Tabela 30 apresenta os experimentos feitos com o conjunto Tr/Te de 30/70. Na Base I, a análise A1 destacou-se na tarefa de classificação com os resultados de sensibilidade igual a 28,57%, especificidade igual a 92,38% e acurácia igual 76,43%. Observa-se que valores maiores de especificidade foram encontrados em outras análises, contudo como já mencionado, procura-se um melhor balanceamento entre as medidas, na ausência, procura-se a análise que obteve melhor resultado para a sensibilidade. Para a Base II, o melhor resultado foi encontrado na análise A1 que obteve sensibilidade de 79,14%, especificidade de 74,86% e acurácia de 77%. Percebe-se que o classificador teve melhor desempenho nas classificações feitas para a Base II em razão da amostra ser melhor balanceada.

Tabela 30 - Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 30/70.

		30/70			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		28,57	92,38	76,43
	A2		17,14	94,29	75,00
	A3		25,71	94,29	77,14
	A4		14,29	95,24	75,00
	A5		20,00	94,29	75,71
	TODOS		11,43	92,38	72,14
BASE II	A1		79,14	74,86	77,00
	A2		82,57	52,86	67,71
	A3		78,29	67,71	73,00
	A4		77,43	72,00	74,71
	A5		77,14	72,57	74,86
	TODOS		80,29	63,71	72,00

Tabela 31 - Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 40/60.

		40/60			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		40,00	96,67	82,50
	A2		10,00	98,89	76,67
	A3		23,33	94,44	76,67
	A4		23,33	93,33	75,83
	A5		20,00	94,44	75,83
	TODOS		16,67	94,44	75,00
BASE II	A1		78,00	73,33	75,67
	A2		78,00	66,33	72,17
	A3		80,67	64,67	72,67
	A4		74,33	72,67	73,50
	A5		73,33	75,00	74,17
	TODOS		70,67	70,67	70,67

Na Tabela 31, são mostrados os experimentos realizados com o conjunto Tr/Te de 40/60. O resultado de sensibilidade igual a 40%, especificidade igual a 96,67% e acuraria de 82,5% fizeram da análise A1 a mais discriminadora entre as análises aplicadas à Base I. Observa-se que o Índice de Simpson em conjunto com as medidas de geometria descreve melhor nódulos benignos na Base I. Nota-se ainda a análise A2 conseguiu a máxima especificidade entre todas as análises com valor de 98,89%. Para a Base II, na

análise A1 encontrou-se a melhor discriminação entre os nódulos com os resultados de sensibilidade igual a 78%, especificidade igual a 73,33% e acurácia igual a 75,67%. A máxima sensibilidade encontrada nesta base está na análise A3 com o valor de 80,67%.

Tabela 32 - Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 50/50.

		50/50			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		44,00	94,67	82,00
	A2		48,00	88,00	78,00
	A3		40,00	89,33	77,00
	A4		24,00	86,67	71,00
	A5		20,00	94,44	75,83
	TODOS		24,00	93,33	76,00
BASE II	A1		83,60	70,00	76,80
	A2		78,40	76,00	77,20
	A3		74,40	73,60	74,00
	A4		70,80	77,20	74,00
	A5		75,60	72,80	74,20
	TODOS		78,80	67,20	73,00

A Tabela 32 mostra os experimentos realizados para o conjunto Tr/Te de 505/50. Observa-se que na Base I, a análise A2 foi apontada como melhor discriminante devido a sensibilidade obtida de 48%, especificidade de 88% e acurácia de 78%. Ressalta-se que na análise A1 obteve valores maiores de especificidade (94,67%) e acurácia (82%), contudo com sensibilidade (44%) inferior a análise A2. Para a Base II, apontou-se a análise A2 como mais balanceada para as medidas avaliativas e conseqüentemente o melhor resultado. Nessa análise a sensibilidade foi de 78,4%, a especificidade foi de 76% e acurácia foi de 77,2%.

Na Tabela 33, encontra-se os resultados dose experimentos feitos com o conjunto Tr/Te de 60/40. A análise A1 demonstrou maior poder discriminatório para a Base I com resultados de sensibilidade igual a 75%, especificidade igual a 93,33% e acurácia de 88,75%. Verifica-se ainda que na análise A3 foi obtida a máxima especificidade entre todas as análises com resultado igual a 96,67%. Para a Base II, encontrou-se na análise A1 o melhor

conjunto de medidas avaliativas. Os resultados obtidos nessa análise foram sensibilidade igual a 80,5%, especificidade igual a 74% e acurácia igual a 77,25%. Nota-se ainda que na análise “TODOS” foi encontrada a máxima sensibilidade entre as análises, o valor obtido foi igual a 83%.

Tabela 33 - Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 60/40.

		60/40			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		75,00	93,33	88,75
	A2		65,00	90,00	83,75
	A3		35,00	96,67	81,25
	A4		15,00	90,00	71,25
	A5		30,00	85,00	71,25
	TODOS		45,00	86,67	76,25
BASE II	A1		80,50	74,00	77,25
	A2		72,50	75,00	73,75
	A3		82,50	69,50	76,00
	A4		75,00	69,50	72,25
	A5		72,00	83,00	77,50
	TODOS		83,00	64,50	73,75

Tabela 34 - Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 70/30.

		70/30			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		73,33	82,22	80,00
	A2		53,33	95,56	85,00
	A3		66,67	88,89	83,33
	A4		33,33	82,22	70,00
	A5		13,33	88,89	70,00
	TODOS		53,33	95,56	85,00
BASE II	A1		82,67	72,67	77,67
	A2		77,33	69,33	73,33
	A3		80,00	78,67	79,33
	A4		76,00	73,33	74,67
	A5		75,33	71,33	73,33
	TODOS		76,67	75,33	76,00

A Tabela 34 apresenta os resultados para o conjunto Tr/Te de 70/30. Verifica-se que na Base I, a análise que teve destaque na discriminação foi A1

que obteve resultados de sensibilidade igual a 73,33%, especificidade igual a 82,22% e acurácia igual 80%. Percebe-se ainda uma melhora de desempenho do classificador com as amostras da Base I. Acredita-se que essa melhora está relacionada com a quantidade de casos existentes no grupo de treinamento o que leva a conclusão que o classificador, para essa base de dados, é dependente da quantidade de casos para a sua aprendizagem. Para a Base II, o melhor resultado obtido está na análise A3, com sensibilidade boa e igual a 80%, especificidade igual a 78,67% e acurácia de 79,33%. Verifica-se ainda que a análise “TODOS” está sobre forte influência da análise A4 devido aos obtidos para sensibilidade (76,67%), especificidade (75,33%) e acurácia (76%) estarem próximos aos encontrados na análise A4.

Tabela 35 - Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 80/20.

		80/20			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		90,00	86,67	87,50
	A2		60,00	86,67	80,00
	A3		60,00	90,00	82,50
	A4		40,00	90,00	77,50
	A5		30,00	86,67	72,50
	TODOS		70,00	90,00	85,00
BASE II	A1		83,00	83,00	83,00
	A2		77,00	71,00	74,00
	A3		83,00	67,00	75,00
	A4		76,00	80,00	78,00
	A5		85,00	75,00	80,00
	TODOS		80,00	66,00	73,00

Na Tabela 35, são apresentados os resultados para os experimentos feito com o conjunto Tr/Te de 80/20. A análise A1 destaca-se com melhor discriminante entre os nódulos da Base I, com valor de sensibilidade igual a 90%, especificidade igual a 86,67% e acurácia igual a 87,5%. Observa-se o conjunto Tr/Te foi o que melhor conseguiu representar casos de nódulos malignos obtendo a máxima sensibilidade entre todos os conjuntos testados para a Base I, esse resultado confirma a afirmativa de que o classificador, para a Base I, consegue melhor desempenho a partir do momento que são fornecidos a ele uma quantidade maior de casos para o

treinamento/aprendizagem. Na Base II, o conjunto Tr/Te aplicado também obteve a máxima estabilidade, que pode ser verificado através dos resultados obtidos na análise A1, considerada mais discriminante. Nessa análise a sensibilidade encontrada foi igual a 83%, a especificidade foi igual 83% e acurácia foi igual 83%.

As Tabelas 36, 37, 38, 39, 40 e 41 descrevem os experimentos realizados dessa abordagem aplicados à Base I e Base II nos conjuntos Tr/Te propostos e submetidos ao classificador MVS de uma classe.

Tabela 36 - Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 30/70.

		30/70			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		25,71	97,33	61,52
	A2		28,57	96,67	62,62
	A3		0,00	100,00	50,00
	A4		17,14	95,33	56,24
	A5		25,71	94,00	59,86
	TODOS		14,29	99,33	56,81
BASE II	A1		73,71	57,58	65,65
	A2		92,57	27,88	60,23
	A3		63,14	59,19	61,17
	A4		61,14	70,51	65,82
	A5		68,29	54,14	61,21
	TODOS		67,71	65,86	66,79

A Tabela 36 mostra os resultados dos experimentos aplicando o conjunto Tr/Te de 30/70. Na Base I, a análise A2 destacou-se com a mais discriminante entre as demais. Obteve-se sensibilidade igual a 28,57%, especificidade igual a 96,67% e acurácia igual a 62,62%. Verifica-se que nessa abordagem e para este classificador, as medidas utilizadas se sobressaem na classificação de casos de nódulos benignos. Na Base II, a análise que obteve melhor resultado foi “TODOS”, na qual os valores de 67,71%, 65,86% e 66,79% encontrados representam sensibilidade, especificidade e acurácia respectivamente. Nota-se que individualmente, na Base II, outras análises obtiveram valores maiores para sensibilidade e especificidade, destaca-se a

análise A2 que obteve sensibilidade no valor de 92,57% e a análise A4 que obteve especificidade no valor de 70,51%.

Na Tabela 37, estão apresentados os experimentos realizados para o conjunto Tr/Te de 40/60. Na Base I, verifica-se que a análise “TODOS” obteve a melhor representação entre os nódulos. Nessa análise a sensibilidade foi igual a 53,33%, especificidade igual a 90,67% e acurácia igual a 72%. Algumas análises apresentaram valores de sensibilidade iguais a zero. Acredita-se que essa situação está relacionada com a predominância do Índice de Simpson sobre as demais medidas no conjunto de variáveis submetidas ao classificador e que o índice apresenta uma similaridade de valores entre os nódulos malignos e benignos. Para a Base II, a análise A5 destacou-se na discriminação com sensibilidade no valor de 69%, especificidade de 63,43% e acurácia de 66,22%. Essa análise foi escolhida como mais representativa devido ao maior balanceamento entre as medidas de sensibilidade, especificidade e acurácia. Contudo, vale ressaltar que individualmente, a análise A1 obteve a máxima sensibilidade entre todas, com valor de 83,67%.

Tabela 37 - Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 40/60.

		40/60		
		Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	Análise			
	A1	36,67	95,33	66,00
	A2	26,67	95,33	61,00
	A3	36,67	96,67	66,67
	A4	0,00	100,00	50,00
	A5	0,00	100,00	50,00
	TODOS	53,33	90,67	72,00
BASE II	A1	83,67	55,35	69,51
	A2	75,67	48,28	61,97
	A3	58,67	59,19	58,93
	A4	69,00	55,96	62,48
	A5	69,00	63,43	66,22
	TODOS	66,00	71,92	68,96

A Tabela 38 descreve os resultados obtidos para o conjunto Tr/Te de 50/50. Os valores de 48%, 84,67% e 66,33% representam a sensibilidade, especificidade e acurácia respectivamente encontradas na análise “TODOS” na

Base I. Essa análise foi considerada a mais representativa entre os experimentos feitos na Base I. Outra vez, percebe-se que a abordagem utilizada está sendo eficaz na representação de casos de nódulos benignos. Para a Base II, os percentuais de 78,4, 65,25 e 71, 83 encontrados na análise “TODOS” são referentes às medidas de sensibilidade, especificidade e acurácia da análise “TODOS” que foi apontada como maior discriminante entre as classes de nódulos malignos e benignos. Ressalta-se, porém, que outras análises conseguiram valores maiores individualmente tanto para sensibilidade quanto como para especificidade. Podem-se citar as análises A1 que obteve especificidade igual a 80,2% e a análise A2 que obteve 84,8% como valor de sensibilidade.

Tabela 38 - Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 50/50.

		50/50		
		Sensibilidade (%)	Especificidade (%)	Acurácia (%)
	Análise			
BASE I	A1	28,00	97,33	62,67
	A2	36,00	95,33	65,67
	A3	36,00	98,00	67,00
	A4	0,00	100,00	50,00
	A5	4,00	96,67	50,33
	TODOS	48,00	84,67	66,33
BASE II	A1	37,60	80,20	58,90
	A2	84,80	34,34	59,57
	A3	66,00	43,43	54,72
	A4	61,60	58,79	60,19
	A5	46,40	72,32	59,36
	TODOS	78,40	65,25	71,83

A Tabela 39 apresenta o resultado dos experimentos realizados para o conjunto Tr/Te de 60/40. A análise A3, na Base I, destacou-se com melhor representativa na tarefa de discriminação entre os nódulos benignos e malignos. Nessa análise, os resultados alcançados podem ser considerados razoáveis. A sensibilidade obtida foi igual a 80%, a especificidade igual a 90,67% e acurácia igual a 85,33%. Para a Base II, a análise “TODOS” apresenta-se como a análise de melhores resultados considerando o balanceamento buscado entre as medidas de avaliação. A sensibilidade

alcançada foi igual a 67,5%, a especificidade foi igual a 74,55% e acurácia igual 71,02%. Destaca-se, porém que a máxima sensibilidade foi encontrada na análise A1 na qual o valor obtido foi de 87,5%.

Na Tabela 40, são mostrados os resultados dos experimentos com o conjunto Tr/Te de 70/30. Verifica-se que na Base I, a análise que se destacou foi A3 onde se encontrou a máxima sensibilidade para o conjunto 70/30 e cujo valor é igual a 53,33%. A especificidade encontrada tem valor de 96% e a acurácia tem valor de 74,67. Para a Base II, os percentuais de 65,33%, 64,85% e 65,09% são referentes à sensibilidade, especificidade e acurácia respectivamente e indicam a análise A4 como melhor representativa devido ao valores balanceados entre as medidas avaliativas. Contudo, observa-se que na análise “TODOS” encontrou-se o maior valor de sensibilidade entre todas as análises, esse valor foi igual a 92%.

Tabela 39 - Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 60/40.

		60/40		
		Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	Análise			
	A1	40,00	91,33	65,67
	A2	60,00	92,67	76,33
	A3	80,00	90,67	85,33
	A4	55,00	90,00	72,50
	A5	45,00	82,67	63,83
	TODOS	45,00	90,67	67,83
BASE II	A1	87,50	45,05	66,28
	A2	83,50	42,83	63,16
	A3	87,00	40,40	63,70
	A4	34,00	74,55	54,27
	A5	74,00	53,33	63,67
	TODOS	67,50	74,55	71,02

A Tabela 41 descreve os resultados encontrados para os experimentos usando o conjunto Tr/Te de 80/20. Para a Base I, a análise “TODOS” destacou-se como melhor representativa onde a sensibilidade obtida foi igual a 70%, a especificidade foi igual a 87,33% e acurácia igual a 78,67%. Percebe-se que nesse conjunto Tr/Te as medidas usadas são melhores para representar nódulos benignos. Nota-se ainda que outras análises obtiveram valores

maiores para especificidade como a análise A1 que conseguiu resultado de 98,67%. Na Base II, a análise A5 obteve sensibilidade de 65%, especificidade de 67,68 e acurácia de 66,34%. Esses resultados, por estarem mais balanceados, qualificam a análise A5 como melhor discriminante embora valores maiores de sensibilidade e especificidade tenham sido alcançados, individualmente, em outras análises. Pode-se citar a análise A3 que obteve valor de sensibilidade igual a 86% e a análise A1 que obteve valor de especificidade igual a 71,52%.

Tabela 40 - Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 70/30.

		70/30			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		0,00	100,00	50,00
	A2		46,67	100,00	73,33
	A3		53,33	96,00	74,67
	A4		40,00	91,33	65,67
	A5		20,00	96,00	58,00
	TODOS		46,67	91,33	69,00
BASE II	A1		78,00	56,97	67,48
	A2		51,33	69,49	60,41
	A3		46,00	66,26	56,13
	A4		65,33	64,85	65,09
	A5		70,67	48,08	59,37
	TODOS		92,00	49,70	70,85

Tabela 41 - Resultados dos testes usando textura extraída em anéis e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 80/20.

		80/20			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	A1		40,00	98,67	69,33
	A2		30,00	98,67	64,33
	A3		50,00	96,00	73,00
	A4		30,00	93,33	61,67
	A5		60,00	40,00	50,00
	TODOS		70,00	87,33	78,67
BASE II	A1		57,00	71,52	64,26
	A2		77,00	47,07	62,04
	A3		86,00	20,61	53,30
	A4		80,00	49,70	64,85
	A5		65,00	67,68	66,34
	TODOS		44,00	70,71	57,35

4.3.2 Textura em Esferas e Geometria

Nesta seção estão descritos os resultados obtidos com a abordagem em círculos para cálculo do Índice de Simpson apresentado na Equação 3 (Seção 2.6.1.1) juntamente com as medidas de geometria propostas na seção 2.6.2. em que pretende-se avaliar o desempenho dos classificadores nessa abordagem.

As Tabelas 42, 43, 44, 45, 46 e 47 descrevem os experimentos realizados dessa abordagem aplicados à Base I e Base II nos conjuntos Tr/Te propostos e submetidos ao classificador MVS tradicional.

A Tabela 42 mostra os resultados obtidos nas análises realizadas com conjunto Tr/Te de 30/70. Na Base I, a análise R6 destacou-se como mais representativa embora o valor de sensibilidade nela encontrado e nas demais análises tenham sido inferiores a 50%. Esse resultado demonstra que a abordagem, considerando esse conjunto Tr/Te, tem baixo desempenho para a caracterização de nódulos malignos. Contudo os valores obtidos para especificidade nesse conjunto apontam para uma boa caracterização de nódulos benignos, destacando valores que chegaram ao resultado de 100% de correta classificação. Na análise R6, a sensibilidade foi igual a 45,71%, a especificidade foi igual a 88,57% e acurácia igual a 77,86%. Para a Base II, a análise que melhor discriminou as classes foi R2, onde a sensibilidade obtida foi igual a 81,71%, a especificidade igual a 68% e acurácia igual a 74,86%.

Na Tabela 43, são mostrados os resultados dos experimentos realizados para o conjunto Tr/Te de 40/60. A análise R2 obteve a melhor discriminação na Base I com sensibilidade de 66,67%, especificidade de 88,89% e acurácia de 83,33%. Neste conjunto Tr/Te, observa-se, novamente, a ocorrência de melhor discriminação de nódulos benignos por parte das medidas utilizadas na abordagem. Verifica-se ainda que outras análises obtiveram valores de especificidade maiores que a análise R2 como na análise R4 onde a especificidade foi igual a 93,33%. Para a Base II, observa-se que as medidas de validação estão mais equilibradas, por essa razão a análise R3 apresenta-se como melhor discriminante para as classes propostas. Ressalta-

se que a análise R2 obteve melhor resultado para sensibilidade com valor igual a 83,33%.

Tabela 42 - Resultados dos testes usando textura extraída em círculos e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 30/70.

		30/70			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		8,57	100,00	77,14
	R2		25,71	94,29	77,14
	R3		20,00	94,29	75,71
	R4		20,00	98,10	78,57
	R5		28,57	96,19	79,29
	R6		45,71	88,57	77,86
	TODOS		20,00	94,29	75,71
BASE II	R1		64,57	81,71	73,14
	R2		81,71	68,00	74,86
	R3		70,57	59,71	65,14
	R4		72,00	76,57	74,29
	R5		72,57	73,43	73,00
	R6		81,14	61,71	71,43
	TODOS		64,29	84,57	74,43

Tabela 43 - Resultados dos testes usando textura extraída em círculos e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 40/60.

		40/60			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		43,33	88,89	77,50
	R2		66,67	88,89	83,33
	R3		40,00	90,00	77,50
	R4		36,67	93,33	79,17
	R5		60,00	84,44	78,33
	R6		60,00	90,00	82,50
	TODOS		46,67	87,78	77,50
BASE II	R1		65,67	79,33	72,50
	R2		83,33	69,67	76,50
	R3		74,67	73,33	74,00
	R4		79,33	71,00	75,17
	R5		76,67	70,00	73,33
	R6		72,33	70,67	71,50
	TODOS		72,67	78,67	75,67

A Tabela 44 apresenta os experimentos para o conjunto Tr/Te de 50/50. Na Base I, a análise R6 encontrou valor de sensibilidade igual a 60%, especificidade igual a 96% e acurácia igual a 87%. Verificasse ainda que valores maiores para especificidade foram encontrados em outras análises. Na análise R3 encontrou-se a máxima especificidade para a Base I, o valor alcançado foi de 97,33%. Para a Base II, observa-se que a análise R2 foi a melhor na tarefa de classificar corretamente os grupos de nódulos. Os percentuais obtidos para sensibilidade, especificidade e acurácia foram iguais a 84,4%, 72% e 78,4%, respectivamente.

Tabela 44 - Resultados dos testes usando textura extraída em círculos e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 50/50.

		50/50			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		48,00	88,00	78,00
	R2		60,00	94,67	86,00
	R3		32,00	97,33	81,00
	R4		20,00	94,67	76,00
	R5		44,00	97,33	84,00
	R6		60,00	96,00	87,00
	TODOS		36,00	94,67	80,00
BASE II	R1		64,00	84,00	74,00
	R2		84,40	72,40	78,40
	R3		82,40	65,20	73,80
	R4		80,80	69,60	75,20
	R5		74,40	76,40	75,40
	R6		69,60	74,40	72,00
	TODOS		70,40	74,80	72,60

Na Tabela 45, são mostrados os resultados dos experimentos realizados para conjunto Tr/Te de 60/40. A análise R3, na Base I, destacou-se devido aos bons resultados obtidos para medidas de validação. Com sensibilidade de 80%, especificidade de 95% e acurácia de 91,25%, encontrados na análise R3, verifica-se que o classificador, conforme diagnosticado em experimentos anteriores, aumenta a capacidade de predição a partir de um número maior de casos para o grupo de treino. Observa-se ainda, que nesta abordagem, as medidas de características utilizadas apresentam melhor caracterização para casos de nódulos benignos. Na Base II, a análise R4 obteve melhor representatividade com resultado de

sensibilidade igual a 79,5%, especificidade igual a 73% e acurácia igual a 76,25%. Contudo percebe-se que individualmente outras análises obtiveram melhores resultados para sensibilidade e especificidade. Na análise R2 encontrou-se a máxima sensibilidade no valor de 88% e na análise R1 encontrou-se a máxima especificidade no valor de 86%.alcança está da análise R5 e tem valor igual a 76,67%.

Tabela 45 - Resultados dos testes usando textura extraída em círculos e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 60/40.

		60/40		
		Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	Análise			
	R1	55,00	91,67	82,50
	R2	60,00	96,67	87,50
	R3	80,00	95,00	91,25
	R4	70,00	90,00	85,00
	R5	40,00	98,33	83,75
	R6	25,00	100,00	81,25
	TODOS	35,00	98,33	82,50
BASE II	R1	60,50	86,00	73,25
	R2	88,00	62,50	75,25
	R3	78,00	73,50	75,75
	R4	79,50	73,00	76,25
	R5	76,50	71,50	74,00
	R6	84,00	69,00	76,50
		TODOS	67,00	79,50

A Tabela 46 apresenta os experimentos realizados para o conjunto Tr/Te de 70/30. Na Base I, a análise R2 é assinalada como maior representativa, nessa análise os valores encontrados para sensibilidade, especificidade e acurácia são 73,33%, 91,11% e 86,67% respectivamente. Ressalta-se que na análise R6 obteve-se a máxima especificidade entre todas as análises com valor igual a 97,78%. Para a Base II, a análise que se destacou como melhor na tarefa de discriminação foi R2 com os percentuais de 86, 76 e 81 que correspondem às medidas de sensibilidade, especificidade e acurácia. A máxima especificidade alcançada está na análise R5 e tem valor de 76,67%.

Tabela 46 - Resultados dos testes usando textura extraída em círculos e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 70/30.

		70/30			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		53,33	91,11	81,67
	R2		73,33	91,11	86,67
	R3		73,33	88,89	85,00
	R4		53,33	86,67	78,33
	R5		53,33	91,11	81,67
	R6		60,00	97,78	88,33
	TODOS		53,33	95,56	85,00
BASE II	R1		61,33	74,67	68,00
	R2		86,00	76,00	81,00
	R3		83,33	65,33	74,33
	R4		81,33	72,00	76,67
	R5		75,33	76,67	76,00
	R6		76,00	75,33	75,67
	TODOS		78,67	71,33	75,00

Tabela 47 - Resultados dos testes usando textura extraída em círculos e geometria, aplicadas à Base I e Base II e classificadas pela MVS tradicional com configuração 80/20.

		80/20			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		70,00	90,00	85,00
	R2		90,00	96,67	95,00
	R3		60,00	90,00	82,50
	R4		60,00	86,67	80,00
	R5		70,00	93,33	87,50
	R6		50,00	93,33	82,50
	TODOS		60,00	93,33	85,00
BASE II	R1		57,00	82,00	69,50
	R2		79,00	78,00	78,50
	R3		73,00	84,00	78,50
	R4		74,00	74,00	74,00
	R5		75,00	71,00	73,00
	R6		78,00	70,00	74,00
	TODOS		82,00	70,00	76,00

A Tabela 47 mostra os resultados para os experimentos realizados com o conjunto Tr/Te de 80/20. Na Base I, identificou-se que a análise R2 conseguiu discriminação satisfatória. Os valores encontrados nessa análise

foram de 90% para sensibilidade, 96,67% para especificidade e 95% para acurácia. Para a Base II, na análise R2 foram obtidos os resultados de 79%, 78% e 78,5% que correspondem às medidas de sensibilidade, especificidade e acurácia e que fazem dessa análise a mais representativa entre as classes de nódulos benignos e malignos.

As Tabelas 48, 49, 50, 51, 52 e 53 descrevem os experimentos realizados dessa abordagem aplicados à Base I e Base II nos conjuntos Tr/Te propostos e submetidos ao classificador MVS de uma classe.

Na Tabela 48, observa-se o desempenho do classificador para os experimentos feito com utilizando a divisão dos grupos de treino e teste segundo o conjunto Tr/Te de 30/70. Para a Base I, o melhor resultado encontrado está na análise R4 na qual se obteve sensibilidade de 11,43%, especificidade de 100% e acurácia de 55,71%. Acredita-se que o baixo desempenho do classificador para este conjunto Tr/Te usando esta base de dados esteja relacionado com a seleção da amostra para o grupo de treino, o leva a conclusão de que o classificador é dependente dos casos escolhidos. Acredita-se ainda que a medida de textura apresentou valores bem similares para as classes de nódulos benignos e malignos e ela teve maior influência durante o processo de treinamento a ponto de dificultar, devido a similaridade dos casos, a aprendizagem causando então os péssimos resultados mostrados. Para a Base II, a análise R4 destacou-se pelos valores encontrados entre as demais análises. Foram obtidos valores de 64,57% para sensibilidade, 63,23% para especificidade e 63,9% para acuraria. Percebe-se ainda, para a Base II, o classificador manteve seu desempenho baixo ainda de acordo com as causas relatadas para a Base I. A diferença é que existe uma pequena relação de perde-ganha entre as medidas de sensibilidade e especificidade que corresponde ao efeito de aumento de medida e decaimento da outra.

Tabela 48 - Resultados dos testes usando textura extraída em círculos e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 30/70.

		30/70			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		0,00	100,00	50,00
	R2		0,00	100,00	50,00
	R3		0,00	100,00	50,00
	R4		11,43	100,00	55,71
	R5		0,00	100,00	50,00
	R6		0,00	100,00	50,00
	TODOS		0,00	100,00	50,00
BASE II	R1		86,29	22,22	54,25
	R2		78,57	31,52	55,04
	R3		65,71	60,61	63,16
	R4		64,57	63,23	63,90
	R5		33,14	75,15	54,15
	R6		44,29	62,22	53,25
	TODOS		61,14	66,87	64,01

Para o conjunto Tr/Te de 40/60, os resultados dos testes realizados são mostrados na Tabela 49. Nota-se que na Base I, os resultados percentuais obtidos na análise R3 garantiram a ela a escolha de medida mais representativa entre as análises. Obteve-se nessa análise sensibilidade no valor de 66,67%, especificidade no valor de 94,67% e acurácia no valor de 80,67%. Ressalta-se que a máxima especificidade obtida está na análise R5 cujo valor foi igual a 97,33%. Para a Base II, segundo os critérios de escolha do melhor resultado buscado, a análise R4 obteve melhor desempenho na tarefa de classificar nódulos. Os valores obtidos foram de sensibilidade igual a 65,67%, especificidade igual a 61,01% e acurácia de 63,34%. Ressalta-se que na análise R3 foi encontrada a máxima sensibilidade (95%) e na análise “TODOS” encontrou-se a máxima especificidade (83,03%).

Tabela 49 - Resultados dos testes usando textura extraída em círculos e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 40/60.

		40/60			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		66,67	83,33	75,00
	R2		66,67	90,00	78,33
	R3		66,67	94,67	80,67
	R4		33,33	88,00	60,67
	R5		56,66	97,33	77,00
	R6		63,33	93,33	78,33
	TODOS		53,33	86,66	70,00
BASE II	R1		63,67	54,95	59,31
	R2		64,67	56,97	60,82
	R3		95,00	24,65	59,82
	R4		65,67	61,01	63,34
	R5		52,67	66,87	59,77
	R6		49,67	52,12	50,89
	TODOS		62,33	83,03	72,68

A Tabela 50 mostra os experimentos feitos com o conjunto Tr/Te de 50/50. Na análise R3, que teve sensibilidade de 64%, especificidade de 93,33% e acurácia de 78,67%, conseguiu-se a melhor discriminação entre as classes desejadas levando em conta o maior valor de sensibilidade encontrado e a falta de balanceamento entre as medidas avaliativas. Destaca-se para o poder de representação de nódulos benignos apresentados por essa abordagem nesse conjunto Tr/Te onde se observa taxas elevadas de especificidade que chegam ao valor de 100%. Na Base II, encontro-se um balanceamento bom e exato em as medidas de sensibilidade, especificidade e acurácia. Em razão dessa ocorrência, a análise “TODOS” tornou-se a melhor discriminante onde os valores apresentados para sensibilidade, especificidade e acurácia são, respectivamente, iguais a: 89,7%, 89,7% e 89,7%.

A Tabela 51 apresenta experimentos usando o conjunto Tr/Tr de 60/40. Com valores de sensibilidade igual a 80%, especificidade igual a 86,67% e 83,33%, a análise R1 destacou-se como melhor discriminante de nódulos para a Base I. Percebe-se que o classificador tem baixo desempenho quando faz a predição da sensibilidade e que tem bom desempenho quando prediz casos benignos. Acredita-se esta ocorrência está relacionada primeiramente com a

quantidade de casos existente na Base I e em seguida com a seleção de casos para os grupos de treinamento e teste. Na Base II, a análise de destaque quanto à capacidade de discriminação foi “TODOS” que obteve sensibilidade de 65%, especificidade de 60% e acurácia de 62,5%. Contudo, ressalta-se a análise R1 que obteve um resultado de acurácia maior que “TODOS” mais que não foi considerada devido ao valor de sensibilidade ser menor em relação à análise “TODOS”. Ressalta-se, ainda, a análise R2 que obteve sensibilidade de 88% e que não foi contada devido ao desbalanceamento existente entre a sensibilidade e especificidade dessa análise.

Tabela 50 - Resultados dos testes usando textura extraída em círculos e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 50/50.

		50/50			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		24,00	92,67	58,33
	R2		64,00	61,33	62,67
	R3		64,00	93,33	78,67
	R4		60,00	92,66	76,33
	R5		24,00	100,00	62,00
	R6		28,00	98,66	63,33
	TODOS		16,00	99,33	57,67
BASE II	R1		78,40	26,46	52,43
	R2		85,20	31,52	58,36
	R3		29,60	75,35	52,48
	R4		65,67	53,54	59,60
	R5		62,40	65,86	64,13
	R6		69,60	48,28	58,94
	TODOS		89,70	89,70	89,70

Tabela 51 - Resultados dos testes usando textura extraída em círculos e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 60/40.

		60/40			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		80,00	86,67	83,33
	R2		35,00	92,00	63,50
	R3		35,00	96,00	65,50
	R4		25,00	99,33	62,17
	R5		55,00	96,66	75,83
	R6		55,00	93,33	74,17
	TODOS		25,00	98,00	61,50
BASE II	R1		60,00	66,87	63,43
	R2		88,00	37,78	62,89
	R3		84,00	44,44	64,22
	R4		24,00	78,79	51,39
	R5		37,50	84,24	60,87
	R6		85,50	31,52	58,51
	TODOS		65,00	60,00	62,50

Tabela 52 - Resultados dos testes usando textura extraída em círculos e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 70/30.

		70/30			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		40,00	95,33	67,67
	R2		40,00	99,33	69,67
	R3		40,00	82,00	61,00
	R4		53,33	78,00	65,67
	R5		80,00	92,00	86,00
	R6		13,33	100,00	56,67
	TODOS		13,33	100,00	56,67
BASE II	R1		66,00	54,75	60,37
	R2		54,67	68,28	61,47
	R3		56,67	68,48	62,58
	R4		68,67	58,79	63,73
	R5		80,00	45,05	62,53
	R6		68,00	53,74	60,87
	TODOS		46,67	75,96	61,31

Na Tabela 52, são mostrados os resultados obtidos através dos experimentos realizados para o conjunto Tr/Te de 70/30. A sensibilidade de 80%, especificidade de 92% e acurácia de 86% garantem à análise R5 boa

capacidade de predição e apontam esta análise com sendo a de melhor discriminação entre as classes de nódulos benignos e malignos para a Base I. Na Base II, a melhor discriminação é conseguida na análise R4 através dos valores de sensibilidade igual a 68,67%, especificidade de 58,79% e acurácia de 63,73%. Porém, destacam-se as análises R6 e “TODOS”, por obterem, individualmente, os valores máximos de sensibilidade (80%) e especificidade (75,96).

Tabela 53 - Resultados dos testes usando textura extraída em círculos e geometria, aplicadas à Base I e Base II e classificadas pela MVS de uma classe com configuração 80/20.

		80/20			
		Análise	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
BASE I	R1		70,00	86,00	78,00
	R2		40,00	100,00	70,00
	R3		40,00	100,00	70,00
	R4		50,00	94,00	72,00
	R5		20,00	100,00	60,00
	R6		40,00	97,33	68,67
	TODOS		50,00	99,33	74,67
BASE II	R1		76,00	52,12	64,06
	R2		84,00	38,79	61,39
	R3		95,00	28,08	61,54
	R4		81,00	43,64	62,32
	R5		52,00	68,08	60,04
	R6		50,00	73,74	61,87
	TODOS		46,00	75,96	60,98

A Tabela 53 mostra os resultados obtidos para os experimentos que foram divididos segundo o conjunto Tr/Te de 80/20. A Base I conseguiu melhor representatividade através da análise R1 na qual foram obtidos valores de sensibilidade de 70%, especificidade de 86% e acurácia de 78%. Para a Base II, a discriminação também aconteceu através da análise R1 onde se encontrou a sensibilidade no valor de 76%, especificidade no valor de 52,12% e acurácia no valor de 64,06%.

4.4 Avaliação Final

Esta seção pretende sintetizar os resultados dos experimentos realizados na metodologia discutindo os melhores resultados obtidos para cada classificador em cada abordagem.

Na abordagem de análise da geometria o classificador MVS tradicional teve melhor desempenho quando realizou avaliação dos dados da Base II onde encontrou taxas de sensibilidade igual 76,67%, especificidade igual 83,33% e acurácia de 80%, possivelmente devido ao equilíbrio no número de casos existente para cada grupo. A MVS de uma classe, entretanto foi melhor quando analisando os dados da Base I onde obteve taxas de sensibilidade de 80%, especificidade de 72,67% e acurácia de 76,33%. O conjunto Tr/Te de 70/30 apareceu como melhor forma de agrupar as amostras de treino e teste para ambos os classificadores.

Utilizando a abordagem representada pela textura, os classificadores avaliaram a medida na análise em anéis e na análise em esferas. O classificador MVS tradicional obteve melhor desempenho que o classificador MVS de uma classe quando analisou os dados da Base I na abordagem em esferas onde a análise de destaque foi R5, que mostrou-se presente em três conjuntos Tr/Te sendo que o mais representativo foi o conjunto 80/20 com taxas de sensibilidade de 70%, especificidade de 100% e acurácia de 92,5%. Ao analisar os dados da Base II, ainda na abordagem em esferas, o classificador MVS de uma classe teve desempenho melhor, nesta situação a análise de destaque foi "TODOS" que registrou três ocorrências entre os conjuntos Tr/Te sendo que mais significativa foi no conjunto 80/20 com as seguintes taxas: sensibilidade de 76%, especificidade de 85,86% e acurácia de 80,93%. Entre todos os experimentos realizados, a análise que teve maior ocorrência, considerando os dois classificadores, foi R2. Analisando a morfologia dos nódulos, supõe-se que nesta região tem-se informações sobre o centro dos nódulos e sabe-se que no centro dos nódulos podem existir condições morfológicas, como necrose ou calcificações, que permitem uma maior diferenciação entre nódulos malignos e benignos.

Ao analisar os dados do Índice de Simpson na abordagem em anéis na Base I, a MVS de uma classe foi mais preditiva que a MVS tradicional, apresentando um bom balanceamento em os valores de sensibilidade, especificidade e acurácia. Para esse classificador as análises de destaque foram A1 e A3 com duas ocorrências de cada uma entre os conjuntos Tr/Te. Na análise A1 obteve-se a melhor predição usando a MVS de uma classe. Os valores observados são: sensibilidade de 70%, especificidade de 88% e acurácia de 79%. Ao analisar os dados do Índice de Simpson, ainda na abordagem em anéis, só que na Base II, a MVS de uma classe ainda manteve-se com melhor desempenho que a MVS tradicional uma vez que teve melhor predição a partir das taxas de sensibilidade igual a 78%, especificidade igual a 79,19% e acurácia igual a 78,6%. A melhor predição encontrada na MVS tradicional foi com sensibilidade de 95,33%, especificidade de 58,67% e acurácia de 77%. As análises de destaque para a MVS de uma classe são “TODOS” com quatro ocorrências entre os conjuntos Tr/Te e A4, com as outras duas ocorrências sendo esta última foi mais discriminante encontrada onde o conjunto Tr/Te foi de 70/30. Verificou-se ainda que entre todos os experimentos realizados nos dois classificadores, a análise que teve maior ocorrência foi A1. Sobre esta região também podem ser extraídas informações significativas a respeito dos nódulos pulmonares. Observando que essa região corresponde a uma área intermediária entre o centro do nódulo e a região mediana e que nessa área pode ser identificada, também características físicas dos nódulos, como aumento de sua circularidade ou prolongamento desordenado. Essas informações tornam-se grande relevância no estudo e determinação de um padrão para estes nódulos.

Para os testes realizados com a medida de textura juntamente com as medidas de geometria. Quando a abordagem considerou o Índice de Simpson calculado em esferas em conjunto com as medidas de geometria, o classificador MVS tradicional foi melhor que o classificador MVS de uma classe ao analisar os dados da Base I. Nessa situação, o classificador obteve taxas satisfatórias para classificação onde a sensibilidade encontrada foi igual a 90%, a especificidade igual a 96,67% e acurácia de 95%. As análises de destaque para esse classificador foram R6 e R2, sendo está última a análise de registro da melhor predição onde o conjunto Tr/Te usado foi 80/20. Ao analisar os

dados da Base II, o classificador MVS de uma classe demonstrou melhor desempenho. As taxas de sensibilidade de 89,7%, especificidade de 89,7% e acurácia de 89,7% foram encontradas na análise “TODOS” com o conjunto Tr/Te de 50/50. As análises de destaque foram “TODOS” com duas ocorrências entre os conjuntos Tr/Te e R4 com três ocorrências.

Analisando os dados da Base I, na abordagem que usa o Índice de Simpson e geometria juntos, onde o índice foi extraído em anéis, a MVS de uma classe apresentou comportamento mais estável na predição de melhor resultado. A sensibilidade obtida foi de 80%, a especificidade foi de 90,67% e acurácia foi de 85,33%. Vale ressaltar que a MVS tradicional, em seu melhor resultado, obteve uma acurácia maior que a MVS de uma classe, contudo apontou-se a MVS de uma classe como de melhor desempenho devido a estabilidade entre as medidas avaliativas e ainda pela melhor predição de casos de nódulos malignos, isto é, maior sensibilidade. As análises de destaque na MVS de uma classe foram “TODOS” com três ocorrências e A3, melhor discriminante usando o conjunto Tr/Te de 60/40, com duas ocorrências. Ao analisar os dados da Base II, verificou-se que a MVS tradicional foi melhor que a MVS de uma classe de acordo com o resultado obtido em sua melhor predição e que foi comparado ao do outro classificador. As taxas obtidas para a MVS tradicional foram de sensibilidade igual a 83%, especificidade igual a 83% e acurácia igual a 83% enquanto que as taxas para a MVS de uma classe foram de sensibilidade de 78,4%, especificidade de 65,25% e acurácia de 71,85%. A análise de destaque para a MVS tradicional foi A1 com quatro ocorrências entre os conjuntos Tr/Te sendo no conjunto 80/20 a ocorrência da melhor classificação.

A Tabela 54 apresenta uma síntese dos melhores resultados obtidos em cada classificador, de acordo com uma abordagem que foi aplicada as duas bases de dados. Os resultados conduzem a conclusão de que a metodologia, de forma geral, foi eficiente na caracterização de nódulos benignos.

Tabela 54 – Síntese de resultados obtidos na metodologia.

Abordagem		MVS tradicional				MVS de uma classe			
		S	E	A	Tr/Te	S	E	A	Tr/Te
Base I	Geometria	65,00	88,33	82,50	60/40	80,00	72,67	76,33	70/30
	Simpson em Anéis	20,00	94,67	76,00	50/50	70,00	88,00	79,00	80/20
	Simpson em Esferas	70,00	100,00	92,50	80/20	90,00	76,00	83,00	60/40
	Simpson em Anéis e Geometria	75,00	93,33	88,75	60/40	80,00	90,67	85,33	60/40
	Simpson em Esferas e Geometria	90,00	96,67	95,00	80/20	80,00	92,00	86,00	70/30
Base II	Geometria	76,67	83,33	80,00	70/30	64,00	63,64	63,82	80/20
	Simpson em Anéis	95,33	58,67	77,00	70/30	78,00	79,19	78,60	70/30
	Simpson em Esferas	67,33	83,33	75,33	70/30	76,00	85,86	80,93	80/20
	Simpson em Anéis e Geometria	83,00	83,00	83,00	80/20	78,40	65,25	71,83	50/50
	Simpson em Esferas e Geometria	86,00	76,00	81,00	70/30	89,70	89,70	89,70	50/50

Conclui-se, ainda, as medidas de geometria, embora com resultados obtidos, sozinhas não garantem uma boa discriminação entre os nódulos. Sobre o Índice de Simpson avaliado, percebe-se que este está mais propício a representar nódulos benignos. E ainda, a união das medidas de geometria em conjunto com o Índice de Simpson garantiu à metodologia seu maior poder discriminatório.

A melhor forma de aplicação da metodologia para extração do Índice de Simpson é considerando as regiões sendo esféricas. Isto se revelou tanto quando da utilização do índice sozinho quanto em conjunto com as medidas geométricas.

Sobre as bases de dados, a Base I apresentou grande desbalanceamento nos conjuntos de treino e testes aplicados. Dessa forma, os resultados obtidos podem não ser conclusivos para as estatísticas calculadas. A Base II por possuir uma maior quantidade de casos, que de forma bem distribuída permitiram, aos classificadores, maior capacidade de aprendizagem.

Os resultados obtidos pela Base II foram de baixa relevância e acredita-se que essa ocorrência possa está relacionada com a segmentação dos nódulos da Base II, que pode ter ocasionado alguma perda de informação e conseqüentemente diminuída a discriminação destes.

A respeito dos classificadores utilizados conclui-se que a MVS tradicional obteve melhor desempenho em grande parte dos testes realizados,

contudo a MVS de uma classe conseguiu estabilizar seus resultados para as estatísticas calculadas em ambas as bases de dados avaliadas. Verifica-se ainda que ambos classificadores somente conseguiram bons resultados a partir das configurações Tr/Te na qual o grupo de treinamento era maior que o grupo de teste. Essa observação aponta que as características, nas várias abordagens, apresentam padrões bastante similares tornando necessário um maior treinamento por parte dos classificadores.

5 CONCLUSÃO

Os elevados índices de mortes e registros de ocorrências de câncer de pulmão no Brasil e no mundo demonstram a importância do desenvolvimento de pesquisas com o objetivo de produzir recursos para um diagnóstico precoce da doença propiciando dessa forma um tratamento mais adequado.

Com isso, o uso de ferramentas computacionais para o diagnóstico tem evoluído em técnicas e áreas de abrangência e, ainda, ganhou interesse por parte da comunidade científica. O resultado é o uso dessas ferramentas para sugerir opiniões a médicos e especialistas e fazê-las aplicáveis cada vez mais, tornando-as presente em seu cotidiano.

Este trabalho apresentou uma metodologia CADx para o diagnóstico de nódulos pulmonares solitários em imagens de tomografia computadorizada através caracterização destes nódulos a partir da extração de medida de textura. Utilizou-se o Índice de Simpson como medida representativa de padrão. Este índice foi avaliado em conjunto com medidas de geometrias submetido aos classificadores Máquina de Vetores de Suporte tradicional e de uma classe.

Os resultados apresentados no Capítulo 4 demonstram o desempenho promissor da metodologia desenvolvida na tarefa de diagnóstico de nódulos pulmonares. Foram obtidos valores de 90% de sensibilidade, 96,67% de especificidade e 95% de acurácia. Com base nestes resultados, observa-se que o Índice de Simpson é uma medida promissora para a caracterização de nódulos pulmonares, principalmente nódulos benignos, e pode fornecer um suporte significativo para uma investigação clínica mais detalhada. Observa-se ainda, que a metodologia utilizada obteve um ganho de desempenho quando reuniu informação do Índice de Simpson e das medidas de geometria. A classificação foi avaliada em duas diferentes abordagens das MVS, qual na metodologia teve maior sucesso quando usou a MVS tradicional. Estas observações a cerca da metodologia podem ainda encorajar trabalhos mais profundos a respeito do uso dessa medida em problemas de reconhecimento de padrões.

Apesar dos bons resultados obtidos, faz-se necessária um melhoramento da metodologia. Nesse sentido são colocados alguns aspectos de melhoria:

Verificar a possibilidade de outra forma de segmentação dos nódulos da Base de dados LIDC a fim de melhorar a informação volumétrica destes nódulos;

Averiguar outras maneiras de extração do Índice de Simpson para o volume do nódulo como, por exemplo, extrair o índice em setores diferentes de uma esfera ou anel que esteja sendo analisado para verificar se em um único setor seja possível encontrar a discriminação.

A partir do processo de melhoria, pode-se sugerir como trabalho de expansão da pesquisa os seguintes itens:

- Pesquisar outras medidas de geometria para caracterização de nódulos pulmonares;

- Pesquisar outras medidas de textura para serem avaliadas e comparadas com o Índice de Simpson;

- Avaliar o uso do Índice de Simpson em conjunto com outras medidas de textura de natureza bioestatística.

- Aplicar o Índice de Simpson em outro classificador e realizar posterior comparação;

- Averiguar a possibilidade de aplicação da metodologia em outras áreas de estudo como na detecção de massa ou não-massa em imagens de mamografia.

REFERÊNCIAS

- ALBUQUERQUE, M. P., ALBUQUERQUE, M. P. **Processamento de imagens**. Centro Brasileiro de Pesquisas Físicas. Disponível em: <<http://www.cbpf.br/cat/pdsi/pdf/ProcessamentoImagens.pdf>>. Acesso em: 25 jan. 2009.
- ARMATO 3rd, S. G.; Li, F.; GIGER, M. L.; MACMAHON, H.; SONE, S.; DOI, K. Lung cancer: performance of automated lung nodule detection applied to cancers missed in a CT screening program. **Radiology**, v. 225, p. 685 – 692, 2002.
- BARROS NETTO, S. M. **Análise de padrões direcionais de nódulos pulmonares em tomografia computadorizada usando estatísticas de Getis como indicador de malignidade e benignidade**. Monografia apresentada ao Curso de Engenharia Elétrica da Universidade Federal do Maranhão. São Luís – MA. 2008.
- BRAZ JUNIOR, G. **Classificação de regiões de mamografia em massa e não massa usando estatística espacial e máquina de vetores de suporte**. Dissertação (Mestrado). Universidade Federal do Maranhão. São Luís, 2008.
- BURGES, C. J. C. **A tutorial on support vector machines for pattern recognition**. Kluwer Academic Publishers, 1998.
- CARVALHO, B. P. R.; BRAGA, A. P. **Estratégias neurais para treinamento de Least Squares Support Vector Machines**. Universidade Federal de Minas Gerais. Belo Horizonte, 2005.
- CAMPOS, V. O. **Segmentação multicritério para detecção de nódulos pulmonares em imagens de tomografia computadorizada**. Proposta de Tese. Pontifícia Universidade Católica do Rio de Janeiro – Brasil, 2008.
- CHANG, C.-C.; LIN, C.-J. **LIBSVM: a Library for Support Vector Machines**. Disponível em <<http://www.csie.ntu.edu.tw/~cjlin/papers/libsvm.pdf>>. Acesso em: 02 jan. 2009.
- CHAVES, A. C. F. **Extração de Regras Fuzzy para Máquinas de Vetor de Suporte (SVM) para Classificação em Múltiplas Classes**. Tese (Doutorado). Pontifícia Universidade Católica do Rio de Janeiro, 2006.

CLUNIE, D. A. **DICOM Structured Reporting**. Pennsylvania: PixelMed Publishing, 2000.

CRISTIANINI, N.; SHAW, J. **An Introduction to support vector machines and other Kernel-Based Learning Methods**. Press Syndicate of the University of Cambridge, 2000.

EL-BAZ, A.; GIMEL'FARB, G.; FALK, R.; EL-GHAR, M. A. A new cad system for early diagnosis of detected lung nodules. **IEEE International Conference on Image Processing**, v. 2, p. 461 - 464, 2007.

FACON, J. **Limiarização bimodal de Otsu**. Notas de Aulas. Programa de Pós-Graduação em Informática Aplicada. Pontifícia Universidade Católica do Paraná – Brasil. Disponível em: <<http://www.ppgia.pucpr.br/~facon/Binarizacao/LimiarOstuNovo3.PDF>>. Acesso em: 20 jan. 2009.

GIGER, M. L. **Computer-aided diagnosis in medical imaging**: a new era in image interpretation. Business Briefing: Next-Generation Healthcare. 2000. Disponível em: <<http://www.wma.net/e/publications/bb2000.htm>>. Acesso em: 08 out. 2007.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. São Paulo: Edgard Blücher, 2000.

HAYKIN, S. **Redes neurais**: princípios e práticas. 2. ed. Porto Alegre: Bookman, 2001.

INCA - INSTITUTO NACIONAL DE CÂNCER. **Estimativa 2008**: Incidência de câncer no Brasil. Rio de Janeiro. 2008. Disponível em: <<http://www.inca.gov.br/estimativa/2008/>>. Acesso em: 19 jan. 2009.

LIANG, T. K.; TOSHIYUKI, T.; NAKAMURA, H.; ISHIZAKA, A. Automatic extraction and diagnosis of lung emphysema from lung CT image using artificial neural network. **SICE-ICASE International Conference**, p. 2306 - 2311, 2006.

LO, S.-C.; HSU, L.-Y.; FREEDMAN, M. T.; LURE, Y. M. F.; ZHAO, H. Classification of lung nodules in diagnostic CT: an approach based on 3-D vascular features, Nodule Density Distributions, and Shape Features. In: Presented at the Society of Photo-Optical Instrumentation Engineers (SPIE) Conference, San Jose, California - EUA. **Proceedings...** The International Society for Optical Engineering, p. 183-189, 2003.

LU, X.; WEI, G.-Q.; QIAN, J. Learning-based pulmonary nodule detection from multislice CT data. In: INTERNATIONAL CONGRESS OF CARS, 18, Chicago - EUA. **Proceedings...** p. 1356, 2004.

LYONS, D. J.; DUNWORTH, P. M.; TILBURY, D. W. **Simpson's Diversity Index**. Offwell woodland and wildlife trust. Disponível em: <<http://www.countrysideinfo.co.uk/simpsons.htm>>. Acesso em: 31 out. 2008.

MANEVITZ, L.; YOUSEF, M. One-class SVMs for document classification. **Journal of Machine Learning Research**, v. 2, p. 139 - 154, 2001.

MARTINS, L. O. **Detecção de massas em imagens mamográficas através do algoritmo Growing Neural Gas e da Função K de Ripley**. Dissertação (Mestrado) apresentada ao Programa de Pós-graduação em Engenharia de Eletricidade. Universidade Federal do Maranhão. São Luís, 2007.

MCNITT-GRAY, M. F.; ARMATO 3rd, S. G.; MCLENNAN, G.; MEYER, C. R.; YANKELEVITZ, D.; ABERLE, D. R.; HENSCHKE, C. I.; HOFFMAN, E. A.; KAZEROONI, E. A.; MACMAHON, H.; REEVES, A. P.; CROFT, B. Y.; CLARKE, L. P. Lung image database consortium research group. Lung image database consortium: developing a resource for the medical imaging research community. **Radiology**, v. 232, nº 3, p. 739 – 48, set. 2004.

MOUSA, W. A. H.; KHAN, M. A. U. Lung nodule classification utilizing support vector machines. In: In IEEE International Conference on Image Processing, Rochester, New York - USA. **Proceedings...** p. 153 -156, 2002.

NAVARRO, F. M. **Estudo comparativo dos pacientes com câncer de pulmão, tabagistas e não tabagistas**. Monografia apresentada ao Curso de Fisioterapia na Universidade Federal do Oeste do Paraná, Cascavel - PR, 2003.

NCI - NATIONAL CANCER INSTITUTE. Lung Cancer. U.S. **National Institute of Health**. 2008. Disponível em: <<http://www.cancer.gov/cancertopics/types/lung>>. Acesso em: 02 jan. 2009.

NEMA - NATIONAL ELECTRICAL MANUFACTURERS ASSOCIATION. **Digital imaging and communications in medicine (DICOM) PS 3-1, 3, 5, 6 e 10**. Estados Unidos. 2004.

NIKOLAIDIS, N.; PITAS, I. **3-D Image processing algorithms**. John Wiley, New York, 2001.

OFFIS - OLDENBURG RESEARCH AND DEVELOPMENT INSTITUTE FOR INFORMATION TECHNOLOGY TOOLS AND SYSTEMS. **DCMTK - DICOM Toolkit**. Alemanha, 1996. Disponível em: < <http://dicom.offis.de/dcmtk.php.en>>. Acesso em: 10 jan. 2009.

OST, D.; FEIN, A. M.; FEINSILVER, S. H. The solitary pulmonary nodule. **New England Journal of Medicine**, v. 25, p. 2535 - 2542, 2003.

OTSU, N. A threshold Selection Method from Gray-Level Histograms. **IEEE Transaction on System, Man, and Cybernetics**, v. SMC-9, nº. 1, p. 62-66, 1979.

PARKER, J. ; DANCE, D. R.; DAVIES, D. H.; YEOMAN, L. J.; MICHELL, M. J.; HUMPHREYS, S. Classification of ductal carcinoma in situ by image analysis of classification from digital mammograms. **The British Journal of Radiology**. v. 68, n. 806, p. 150 - 159, 1995.

PELDSCHUS, K.; HERZOG, P.; WOOD, S. A.; CHEEMA, J. I.; COSTELLO, P.; SCHOEPF, J. Computer-aided diagnosis as a second reader: spectrum of findings in CT studies if chest interpreted as normal. **Chest**, v. 123, p. 1517 – 1523, 2005.

PETKOVSKA, I.; SHAH, S. K.; MCNITT-GRAY, M. F.; GOLDIN, J. G.; BROWN, M. S.; KIM, H. J.; BROWN, K.; ABERLE, D. R. Pulmonary nodule characterization: a comparison of conventional with quantitative and visual semi-quantitative analyses using contrast enhancement maps. **European Journal of Radiology**, v. 59, 244 - 252, 2006.

RICKLEFS, R. E. **The economy of nature**: a textbook in basic ecology. W. H. Freeman and Company, 1993.

SCHÖLKOPF, B.; SMOLA, A. J.; BARLETT, P.; SCHUURMANS, D. **Introduction to large margin classifiers**. 1999. p. 193 – 216.

SCHÖLKOPF, B.; SMOLA, A.; PLATT, J.; SHAWE-TAYLOR, J.; WILLIAMSON, R. Estimating the support of a high-dimensional distribution. **Neural Computation**, v. 13, p. 1443 - 1471, 2001.

SCHÖLKOPF, B.; SMOLA, A. **Learning with kernels**: support vector machines, regularization, optimization, and beyond. MIT Press, 2002.
SHAH, M. F.; SUMIT, K.; MCNITT-GRAY, S. R.; ROGERS, J. G.; GOLDIN, R. D.; SUH, J. W.; SAYRE, I. P.; HYUN, J. K.; DENISE, R. A. Computer aided characterization of the solitary pulmonary nodule using volumetric and contrast enhancement features. **Academic Radiology**, v. 12, p. 1310 - 1319, 2005.

SILVA, A. C.; FERREIRA JUNIOR, P. E.; CARVALHO, P. C. P.; GATTASS, M. Diagnosis of lung nodule using the semivariogram function. **Lecture Notes in Computer Science**, v. 3138, p. 242 - 250. out. 2004.

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, 2004.

SILVA, A. C.; CARVALHO, P. C. P. Sistema de análise de nódulo pulmonar. In: **II Workshop de Informática aplicada a Saúde**, Universidade de Itajaí, Itajaí, 2002. Disponível em: <<http://www.cbcomp.univali.br/pdf/2002/wsp035.pdf>>. Acesso em: 20 set. 2008.

SILVA, E. C. “**Diagnóstico de nódulo pulmonar assistido por computador usando técnicas de processamento de imagens, índice de Moran e coeficiente de Geary**”. Monografia apresentada ao Curso de Engenharia Elétrica na Universidade Federal do Maranhão. São Luís, 2007.

SILVA, E. C.; SILVA, A. C.; PAIVA, A. C.; NUNES, R. A. Diagnosis of lung nodule using Moran's index and Geary's coefficient in computerized tomography images. **Pattern Analysis & Applications**, v. 11, p. 89 - 99, 2007.

SILVA, E. C.; SILVA, A. C.; PAIVA, A. C.; NUNES, R. A.; GATTASS, M. Diagnosis of solitary lung nodules using the local form of Ripley's K function applied to three-dimensional CT data. **Computer methods and Programs in Biomedicine**, v. 90, p. 230 - 239, 2008.

SIMPSON, E. H. “Measurement to diversity”. **Nature**, v. 163, p. 688.

SOARES, F. A. P. **Produção de raios x em ampolas radiográficas**: estudo do tomógrafo computadorizado do Hospital regional de São José/SC. Florianópolis. 2006. Tese (Doutorado em Física Experimental)-Universidade Federal de Santa Catarina.

SOARES, R. C. **Estudo de código de barras por análise de imagens**. Dissertação de Mestrado em Engenharia Elétrica com área de concentração em Engenharia de Computação, Universidade Estadual de Campinas – Brasil, 2001.

SONKA, M; HLAVAC, V; BOYLE, R. **Image processing, analysis, and machine vision**. Thomson-Engineering. 2. ed. 1998. Disponível em: <<http://www.icaen.uiowa.edu/~dip/LECTURE/lecture.html>>. Acesso em: 12 out. 2008.

SOUSA, J. R. F. S. **Metodologia para detecção automática de nódulos pulmonares**. Dissertação de Mestrado do Programa de Pós-graduação em Engenharia da Eletricidade, Universidade Federal do Maranhão – Brasil, 2007.

SOUSA, J. R. F. S.; SILVA, A. C.; PAIVA, A. C. Lung structure classification using 3D geometric measurements and SVM. Progress in Pattern Recognition, Image Analysis and Applications. Lecture Notes in Computer Science. **Springer Berlin/Heidelberg**, v. 4756, p. 783 - 792, 2008.

SUYKENS, J. A. K.; HAMERS, B.; VANDEWALLE, J. Least squares support vector machine classifiers. **Neural Processing Letters**, v. 9, n. 3, p. 293 - 300, 1999.

SUYKENS, J. A. K.; HAMERS, B.; DE MOOR, B. **A comparison of iterative methods for least squares support vector machine classifiers**. Technical report, ESAT-SISTA, K.U. Leuven. 2001.

SWENSEN, S. J. Pulmonary nodules: CT evaluation of enhancement with iodinated contrast material. **Thoracic Radiology**, v. 194, 393 - 399, 1995.

SWENSEN, S. J. Lung Nodule Enhancement at CT: Multicenter Study. **Radiology**, v. 214, 73 - 80, 2000.

SWENSEN, S. J.; JETT, J. R.; SLOAN, J. A.; MIDTHUN, D. E.; HARTMAN, T. E.; SYKES, A.; AUGHENBAUGH, G. L.; ZINK, F. E.; HILLMAN, S. L.; NOETZEL, G. R.; MARKS, R. S.; CLAYTON, A. C.; PAIROLERO, P. C. Screening for lung cancer with low dose spiral computed tomography. **Am J Respir Crit Care Med**, v. 20, p. 911 – 920, 2002.

SZARF, G.; SOUZA, R. **Tudo sobre Saúde; Conheça seus exames: Nódulo pulmonar**. Disponível em: <http://www.lincx.com.br/lincx/saude_a_z/conheca_exames/nodulo_pulmonar.a_sp>. Acesso em: 19 jan. 2009.

TARANTINO, A. B. **Nódulo solitário do pulmão**. 4. ed. Rio de Janeiro: Guanabara. Koogan, 1997.

TRAN, Q.; ZHANG, Q.; LI, X. **Evolving training model method for one-class SVM**. Systems, Man and Cybernetics, IEEE International Conference, 2003.

UEHARA, C.; JAMNIK, S.; SANTORO, I. L. Câncer de pulmão. **Medicina**, Ribeirão Preto - RJ, 31, p. 266 - 276, Jun. 1998.

UNIVERSITY OF GUELPH. **Shape analysis & measurement**, CIS*6320, Lecture Notes, 2001.

VAPNICK, V. **Statistical learning theory**. J.Wiley and Sons Inc. Nova York, 1995.

WHITE, C. S.; PUGATCH, R.; KOONCE, T.; RUST, S. W.; DHARAIYA, E. Lung nodule CAD software as a second reader: a multicenter study. **Academic Radiology**, v. 15, n. 3, p. 326 - 333, DOI: 10.1016/j.acra.2007.09.027, 2008.

WILEY, J. **Neural and adaptive systems: fundamentals through simulations**. E-book: NeuroDimension, 2000.

ZHAO, B.; GANSU, G.; GINSBERG, M. S.; JIANG, L.; SCHWARTZ, L. H. Automatic detection of small lung nodules on CT utilizing a local density maximum algorithm. **Journal of Applied Clinical Medical Physics**. v. 4, n. 3, p. 248 - 260, 2003.

ZHAO, B.; GINSBERG, M. S.; LEFKOWITZ, R. T. A.; JIANG, L.; SCHWARTZ, L. H. Application of the LDM algorithm to identify small lung nodules on low-dose MSCT scans. In: Presented at the Society of Photo-Optical Instrumentation Engineers (SPIE) Conference, Valparaiso - Chile. **Proceedings...** The International Society for Optical Engineering. p. 818 - 823, 2004.

APÊNDICE A – Método de Otsu.

Método de Otsu

Sejam os pixels de uma imagem representados por L níveis de cinza $[1, 2, 3, \dots, L]$. O número de pixels presente na imagem com intensidade de cinza i é denotado por n_i e o total de pixels presentes na imagem por $N = n_1 + n_2 + n_3 + \dots + n_L$. Normaliza-se o histograma, acumulando-o como uma distribuição de probabilidade para cada ocorrência do nível de cinza i .

$$p_i = n_i/N \quad (\text{A1})$$

Em seguida, dividimos os pixels em duas classes C_0 e C_1 (plano de fundo e objetos) por meio de um valor de limiar k . A classe C_0 indica os pixels com níveis em $[1, 2, \dots, k]$ e C_1 denota os pixels com níveis em $[k + 1, k + 2, \dots, L]$. A probabilidade de ocorrência das classes C_0 e C_1 e suas médias são dadas por:

$$\omega_0 = \sum_{i=0}^k p_i \quad (\text{A2})$$

$$\omega_1 = 1 - \omega_0 \quad (\text{A3})$$

$$\mu_0 = \mu_K / \omega_0 \quad (\text{A4})$$

$$\mu_1 = \frac{\mu_T - \mu_K}{1 - \mu_0} \quad (\text{A5})$$

Então são estabelecidas medidas indicadoras de separabilidade, ou seja, fatores que impõem critérios para a determinação de um valor de limiar eficaz; dadas por:

$$\lambda = \sigma_B^2 / \sigma_W^2, \quad \kappa = \sigma_T^2 / \sigma_W^2, \quad \eta = \sigma_B^2 / \sigma_T^2 \quad (\text{A6})$$

Onde:

$$\sigma_W^2 = \omega_0^2 \sigma_0^2 + \omega_1^2 \sigma_1^2 \quad (\text{A7})$$

$$\sigma_B^2 = \omega_0 \omega_1 (\mu_1 \mu_0)^2 \quad (\text{A8})$$

$$\sigma_T^2 = \sum_{i=0}^{L-1} (i - \mu_T)^2 p_i \quad (\text{A9})$$

Adotando η como critério de eficiência da escolha de um valor k como limiar, devemos considerar que o valor otimizado (k^*) será aquele que maximiza η , ou de forma equivalente, maximiza σ_B^2 . O valor de η é invariante para transformações afins da escala de níveis de cinza e é unicamente determinado dentro do intervalo:

$$0 \leq \eta \leq 1 \quad (\text{A10})$$

O limite inferior (zero) é obtido quando e somente quando uma dada imagem tenha um único e constante nível de cinza e o limite superior (um) é obtido quando e somente quando imagens de dois valores são dadas.