

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE MINAS GERAIS
Programa de Pós-Graduação em Engenharia Elétrica

André Luís Resende Monteiro

**SEGMENTAÇÃO DE IMAGENS PET/CT UTILIZANDO
TOMADA DE DECISÃO MULTICRITÉRIO**

Belo Horizonte

2013

André Luís Resende Monteiro

**SEGMENTAÇÃO DE IMAGENS PET/CT UTILIZANDO
TOMADA DE DECISÃO MULTICRITÉRIO**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Pontifícia Universidade Católica de Minas Gerais, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Alexei Manso
Corrêa Machado

Co-orientador: Prof. Dr. Marcelo Henrique Mamede Lewer

Belo Horizonte

2013

FICHA CATALOGRÁFICA

Elaborada pela Biblioteca da Pontifícia Universidade Católica de Minas Gerais

M775s Monteiro, André Luís Resende
Segmentação de imagens PET/CT utilizando tomada de decisão multicritério / André Luís Resende Monteiro. Belo Horizonte, 2013. 74f. : il.

Orientador: Alexei Manso Corrêa Machado
Coorientador: Marcelo Henrique Mamede Lewer
Dissertação (Mestrado) – Pontifícia Universidade Católica de Minas Gerais.
Programa de Pós-Graduação em Engenharia Elétrica

1. Tomografia computadorizada. 2. Tomografia computadorizada de emissão. 3. Processo decisório por critério múltiplo. 4. Processamento de imagens. I. Machado, Alexei Manso Corrêa. II. Lewer, Marcelo Henrique Mamede. III. Pontifícia Universidade Católica de Minas Gerais. Programa de Pós-Graduação em Engenharia Elétrica IV. Título.

SIB PUC MINAS

CDU: 615.849

André Luís Resende Monteiro

SEGMENTAÇÃO DE IMAGENS PET/CT UTILIZANDO TOMADA DE DECISÃO MULTICRITÉRIO

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica como requisito parcial para qualificação ao Grau de Mestre em Engenharia Elétrica pela Pontifícia Universidade Católica de Minas Gerais.

Prof. Dr. Alexei Manso Corrêa Machado –
PUC Minas

Prof. Dr. Marcelo Henrique Mamede Lewer
– PUC Minas

Prof. Dr. Carlos Augusto Paiva da Silva
Martins – PUC Minas

Prof. Dr. David Menotti Gomes – UFOP

Belo Horizonte, 12 de julho de 2013.

AGRADECIMENTOS

Agradeço a Deus, pois sem Ele nada aconteceria.

Ao meu orientador, Dr. Alexei Manso Corrêa Machado, e ao meu co-orientador, Dr. Marcelo Henrique Mamede Lewer, pelas contribuições essenciais e sabedoria na condução deste trabalho.

À minha família, por todo o apoio.

À minha namorada, Simone, pela ternura e compreensão.

Aos meus amigos, pelo incentivo e por ouvirem em inúmeras vezes meus desalentos e reclamações.

“Prefiro trabalhar no impossível, pois lá a concorrência é menor”

Walt Disney

RESUMO

A correta mensuração do volume de tumores em imagens médicas tem se tornado um requisito fundamental para um correto planejamento e subsequente tratamento do câncer. Se um tumor é precisamente delimitado, o planejamento de radioterapias torna-se muito mais efetivo, já que se consegue atingir com maior precisão as células cancerígenas e poupa as células vizinhas sadias. Dessa forma, procura-se otimizar os métodos automatizados de segmentação de tumores em imagens de diversos tipos de exames. Especialmente, a utilização de informações oriundas tanto de imagens estruturais quanto de funcionais pode trazer um aumento na efetividade desses métodos, posto que essas duas modalidades de exames apresentam características singulares que podem ser exploradas em conjunto. Exemplos de imagem de caráter estrutural e funcional, são, respectivamente, os exames de tomografia computadorizada (CT) e tomografia por emissão de pósitrons (PET). Esse trabalho se propõe a adaptar o algoritmo crescimento de região para utilizar a abordagem de tomada de decisão multicritério (MCDM) no processo de segmentação de tumores, utilizando para isso tanto características oriundas dos exames de PET quando de CT.

Palavras-chave: Segmentação, imagens funcionais, imagens estruturais, imagens médicas, PET, CT, MCDM, multicritério

ABSTRACT

Accurate delineation of tumor cells is a fundamental requirement to a proper planning and subsequent cancer treatment. If a tumor is precisely delimited, the chemotherapy becomes much more effective, as it reaches the cancer cells and spare healthy cells. With this objective, positron emission tomography/computed tomography (PET/CT) begins to be investigated, and showed great results in tumors segmentation. In another way, the process of image segmentation can be viewed as a typically multicriteria decision making (MCDM) problem, since the constituent pixels of an object should be grouped or not depending on the analysis of various factors. In this work, we propose the modeling of the process of cervical tumor segmentation as a multicriteria decision making problem, and the utilization of classifiers that uses all of these criterias to guide the segmentation process and uses both PET and CT images. The results showed that the utilization of multiple criterias in the segmentation process can improve the sensibility, and the joint utilization of both PET and CT images may be factor for improving the precision obtained in the process.

Keywords: Image segmentation, functional imaging, structural imaging, medical imaging, PET, CT, MCDM, multicriteria.

LISTA DE FIGURAS

FIGURA 1 – Imagem de CT do cérebro	24
FIGURA 2 – Imagem de MRI do cérebro	24
FIGURA 3 – Imagem de PET da região do cérebro	24
FIGURA 4 – Processo de segmentação de tumores	25
FIGURA 5 – Funcionamento do crescimento de região	36
FIGURA 6 – Matriz a partir da qual será calculada a SGLDM	38
FIGURA 7 – Matriz SGLDM calculada a partir da Figura 6	38
FIGURA 8 – Exemplo de classificação utilizando o k -NN	41
FIGURA 9 – Exemplo de matriz usada no LDA	42
FIGURA 10 – Matriz representando as alternativas, pesos e critérios em um problema de tomada de decisão multicritério	44
FIGURA 11 – Matriz representando um problema multicritério	45
FIGURA 12 – Resultado da segmentação multicritério de tumores	62
FIGURA 13 – Imagem segmentada com 95% de sensibilidade utilizando PET e MRI (traço amarelo) sobre a imagem de MRI	64
FIGURA 14 – Imagem segmentada com 96% de sensibilidade na PET e CT (traço amarelo) sobre a imagem de MRI	64
FIGURA 15 – Imagem segmentada com 87% de sensibilidade na PET e CT (traço amarelo) sobre a imagem de MRI	65
FIGURA 16 – Imagem segmentada com 87% de sensibilidade na PET/CT sobre a imagem de PET (traço amarelo)	65
FIGURA 17 – Resultado do teste t para os classificadores multicritério	66
FIGURA 18 – Resultado do teste t em função do tipo de imagem utilizada	67

LISTA DE GRÁFICOS

GRÁFICO 1 – Resultado da segmentação multicritério de tumores utilizando imagem de PET	61
GRÁFICO 2 – Resultado da segmentação multicritério de tumores utilizando imagens de PET e CT	61
GRÁFICO 3 – Resultado da segmentação multicritério de tumores utilizando imagens de PET e MRI	62
GRÁFICO 4 – Resultado da segmentação de tumores utilizando limiar de tons de cinza	63
GRÁFICO 5 – Desempenho médio das técnicas de multicritério na segmentação de tumores	63
GRÁFICO 6 – Desempenho médio em função da quantidade de sementes utilizadas	66

LISTA DE ABREVIATURAS E SIGLAS

- CT Tomografia Computadorizada
- DE *Differential Evolution*
- EGC Eletrocardiograma
- fMRI *Ressonância Magnética Funcional*
- LDA Análise de Discriminante Linear
- MCDM *Tomada de Decisão Multicritério*
- MRI Ressonância Magnética
- NCI *National Cancer Institute*
- NGTDM *Neighborhood Gray-tone-difference Matrix*
- NN *Nearest Neighbor*
- OMS Organização Mundial da Saúde
- PET Tomografia por Emissão de Pósitrons
- SGLDM *Spatial Grey-level Dependences Matrices*
- SUV *Standardized Uptake Value*
- TRINOMFC *TRI NOMinal bas e sur des Fonctions Crit eres*
- VNS *Variable Neighborhood Search*
- WPM *Weighted Product Model*
- WSM *Weighted Sum Model*

SUMÁRIO

1	INTRODUÇÃO.....	23
1.1	Motivação.....	25
1.2	Objetivos	26
1.3	Contribuições	26
1.4	Escopo.....	27
1.5	Organização do trabalho.....	27
2	REVISÃO BIBLIOGRÁFICA.....	28
2.1	Segmentação de tumores utilizando informações de PET e de CT combinadas	28
2.2	Análise Multicritério em problemas de classificação	31
3	SEGMENTAÇÃO DE IMAGENS.....	35
3.1	Características de imagens.....	36
3.1.1	<i>Características de Primeira Ordem</i>	37
3.1.2	<i>Características de Segunda Ordem</i>	37
3.1.3	<i>Características de Alta Ordem</i>	38
3.1.4	<i>Características Estruturais</i>	39
3.1.5	<i>Características Específicas</i>	39
3.2	Funções de decisão	40
3.2.1	<i>k-NN</i>	40
3.2.2	<i>Análise de Discriminante Linear (LDA)</i>	41
3.2.3	<i>Naive Bayes</i>	42
4	TOMADA DE DECISÃO MULTICRITÉRIO	44
4.1	Métodos de tomada de decisão multicritério	44
4.1.1	<i>Weighted Sum Model (WSM)</i>	44
4.1.2	<i>Weighted Product Model (WPM)</i>	45
4.2	Classificação Multicritério	46
4.2.1	<i>PROAFTN! (PROAFTN!)</i>	47
4.2.1.1	<u>Relação de concordância</u>	48

4.2.1.2	<u>Relação de discordância</u>	49
4.2.1.3	<u>Relação de indiferença</u>	50
4.2.2	<i>Differential Evolution</i>	51
4.2.2.1	<u>DERPRO</u>	52
5	MÉTODO MULTICRITÉRIO DE SEGMENTAÇÃO DE IMAGENS PET/CT	54
6	EXPERIMENTOS E RESULTADOS	58
6.1	Aquisição e pré-processamento	58
6.2	Experimentos	59
6.3	Resultados	60
6.4	Considerações finais	66
7	CONCLUSÃO E TRABALHOS FUTUROS	68
7.1	Trabalhos Futuros	68
	REFERÊNCIAS	70

1 INTRODUÇÃO

O câncer é uma doença que tem crescido muito nos últimos anos. Segundo a Organização Mundial da Saúde (OMS), 7,6 milhões de pessoas morreram de câncer em todo o mundo, em 2005, e, em 2015, a enfermidade deve ser responsável pelo óbito de mais nove milhões. Ainda de acordo a organização, 13% de todas as mortes no mundo, em 2005, foram causadas pela doença¹. No Brasil, de acordo com dados do Ministério da Saúde², mais de 618 mil pessoas morreram acometidas pela doença, no ano de 2011, apenas no sistema público de saúde.

Segundo o *National Cancer Institute* (NCI)³, o câncer é causado pelo crescimento desordenado das células, que podem acabar ocupando o espaço de outros tecidos do organismo. A maioria dos cânceres possuem sua denominação dependendo do órgão ou tipo de célula em que ele começa. Por exemplo, o câncer que se origina no colo do útero é denominado câncer de colo do útero, e o carcinoma é um câncer que tem origem epitelial.

Nesse contexto, a radioterapia, um método não invasivo para o tratamento do câncer, surge como um dos pilares do tratamento moderno da enfermidade, sendo executada individualmente ou com o auxílio de outras técnicas, como a quimioterapia ou a cirurgia (AGENCY, 2007). Na radioterapia, os tumores malignos devem ser completamente atingidos com doses de radiação de forma a destruir as células tumorais. Um tratamento ideal que emprega essa técnica deve ser capaz de aplicar a dose suficiente de radiação para controlar o crescimento dos tumores ou causar sua destruição, e, ao mesmo tempo, atingir o mínimo possível as células vizinhas saudáveis, já que elas irão proporcionar a regeneração das áreas danificadas pelo tratamento. Dessa forma, o correto delineamento da localização e do tamanho dos tumores assume papel fundamental no planejamento e na execução do tratamento do câncer.

De forma a realizar a mensuração do tamanho do tumor e a sua localização, especialistas realizam o seu delineamento a partir de diversos tipos de exames, que geram imagens com características distintas. Uma das primeiras imagens a ser utilizada foi a Tomografia Computadorizada (CT)⁴. Uma das principais inovações desse tipo de exame foi o fato de produzir imagens das estruturas internas do corpo. Nesse tipo de exame, a área de interesse do paciente é exposta a um grande número de raios X. Outro tipo de exame vem tomando gradativamente o lugar das imagens de CT: a Ressonância Magnética (MRI)⁵. Suas principais vantagens em relação à sua predecessora são a capacidade de gerar imagens de maior resolução e contraste, permitir uma maior liberdade nos parâmetros para

¹<http://www.who.int/mediacentre/releases/2003/pr27/en>

²<http://www2.datasus.gov.br/DATASUS/index.php?area=0203>

³<http://www.cancer.gov>

⁴Do inglês, Computed Tomography

⁵Do inglês, Magnetic Resonance Imaging

aquisição das imagens e utilizar radiação não-ionizante, em oposição aos raios X usados no exame da tomografia computadorizada (KLINOWSKI, 1993). Tanto a CT quanto a MRI fazem parte do grupo denominado imagens estruturais, que apresentam, como principais benefícios à identificação dos tumores por especialistas, o fato de possuírem grande resolução espacial, o que permite visualizar com clareza as diferentes estruturas internas do corpo humano. Contudo, apesar do grande detalhamento anatômico, possuem a desvantagem de não apresentar um contraste alto entre os tumores e tecidos saudáveis. As Figuras 1 e 2 mostram, respectivamente, o resultado de um exame de CT e de MRI.




Figura 1 – Imagem de CT do cérebro **Figura 2 – Imagem de MRI do cérebro**

Outra categoria de imagens, as funcionais, diferentemente das estruturais, caracterizam-se por captar as diferentes atividades metabólicas que ocorrem no corpo do ser humano. Um das principais imagens que integram essa categoria é a *Ressonância Magnética Funcional* (fMRI)⁶. Nela, as atividades do cérebro são mensuradas através das alterações que ocorrem com o fluxo sanguíneo. Outra forma de aquisição de imagens é a Tomografia por Emissão de Pósitrons (PET)⁷. Nesse exame, um radiofármaco é injetado no paciente. Dessa forma, as regiões internas que estão metabolizando mais glicose, com maiores chances de serem tecidos doentes, são marcadas na imagem produzida (AMETAMEY; SCHUBIGER, 2008). Conseqüentemente, os resultados obtidos, ao se utilizar PET, apresentam um contraste maior que as imagens estruturais, já que diferem os tecidos com maior atividade metabólica daqueles com menor. Porém, a intensidade metabólica na imagem produzida diminui gradativamente, o que dificulta a delimitação exata de tumores. A Figura 3 mostra uma imagem de PET da região do cérebro.




Figura 3 – Imagem de PET da região do cérebro

⁶Do inglês, Functional Magnetic Resonance Imaging

⁷Positron emission tomography

Com o intuito de auxiliar o tratamento do câncer, faz-se necessário o desenvolvimento de técnicas automatizadas de segmentação de imagens de tumores. A segmentação pode ser definida como o processo de subdividir uma imagem nas partes ou objetos que a constituem (GONZALEZ, 2007). Assim, a segmentação deve ir até o ponto no qual os objetos de interesse sejam isolados do restante da imagem. A segmentação autônoma é uma das tarefas mais difíceis em processamento de imagens, podendo determinar o eventual fracasso ou sucesso da análise. O processo de segmentação de um tumor em uma imagem médica pode ser visualizado na Figura 4. Uma vez que a imagem é coletada, ela é segmentada com algum algoritmo automático ou semi-automático e então a imagem com os tumores identificados é produzida.

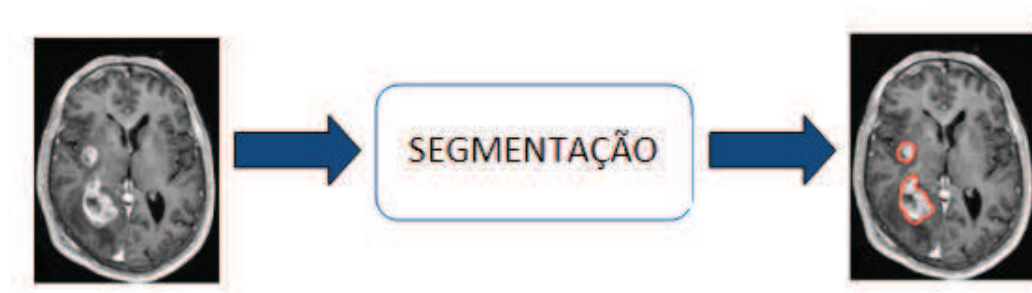


Figura 4 – Processo de segmentação de tumores

O processo de segmentação, no que se refere à escolha dos pixels que irão fazer parte da imagem final, tradicionalmente leva em consideração a relação de intensidade entre os pixels vizinhos. Dessa forma, caso dois pixels possuam uma diferença de intensidade considerada aceitável (definida durante a modelagem do problema), eles são, via de regra, considerados como pertencentes ao mesmo objeto na imagem. Contudo, também é possível realizar a coleta de outras características para o processo de segmentação de tumores, como a entropia entre um conjunto de pixels ou o desvio-padrão das suas intensidades.

O desenvolvimento de tecnologias automatizadas de segmentação de tumores, fazendo uso de dados conjuntos, tanto de imagens funcionais quanto estruturais, pode trazer ganhos na mensuração dos volumes dos tumores, e conseqüentemente, no tratamento do câncer, como apontado por Schiepers et al. (2002).

1.1 Motivação

A segmentação automatizada de tumores é uma ferramenta importante de auxílio ao médico para um correto planejamento e execução de tratamento contra o câncer, além do acompanhamento da evolução da doença. Ela poderá contribuir com uma delimitação mais precisa e rápida, não sendo afetada por fatores humanos, como a falta de experiência ou a fadiga.

A utilização combinada de dados de imagens de PET e de CT para a identificação de tumores vem apresentando bons resultados se comparados aos métodos tradicionais de segmentação. Acredita-se que seus produtos de trabalho podem contribuir consideravelmente para uma mensuração mais precisa do volume de tumores malignos, o que contribuirá para um tratamento mais eficaz no combate ao câncer. Além disso, a utilização de *scanners* que geram imagens de PET e de CT conjuntas (denominada tecnologia PET/CT) é muito maior do que a utilização de *scanners* que geram imagens de PET e de MRI, visto que são mais viáveis economicamente. Dessa forma, é justificável a investigação de técnicas de segmentação que utilizam esses tipos de imagens.

1.2 Objetivos

Os objetivos deste trabalho são:

- coletar características das imagens de PET e de CT, não se limitando à intensidade dos pixels, que podem ser utilizadas no processo de segmentação de tumores.
- utilizar as características selecionadas em um processo de decisão multicritério, de forma a determinar se dois pixels pertencem ou não ao mesmo objeto em uma imagem.
- adaptar o algoritmo de segmentação por crescimento de região para levar em consideração o conjunto de características selecionadas e não somente a intensidade dos pixels, para realizar a segmentação de tumores em imagens de câncer de colo de útero.
- utilizar as imagens de PET e de CT de forma conjunta no momento de segmentação das imagens.
- avaliar a exatidão da delimitação dos tumores de câncer de colo de útero da técnica desenvolvida, quando comparada à segmentação manual realizada por um especialista médico.
- comparar o resultado da segmentação ao se utilizar imagens de PET e de CT com a segmentação utilizando imagens de MRI, que apresentam qualidade e resolução superiores.
- comparar os resultados das técnicas utilizadas com a segmentação a partir de limiar de tons de cinza.

1.3 Contribuições

As contribuições principais desse trabalho são:

- a utilização de diversas características das imagens de PET e de CT no momento de segmentação de tumores.

- a utilização de métodos de classificação multicritério no processo de segmentação.
- a mensuração da precisão de delimitação dos tumores das técnicas utilizadas.
- a comparação dos métodos multicritérios com a segmentação utilizando limiar de tons de cinza.

1.4 Escopo

O escopo do trabalho desenvolvido limitou-se a:

- realizar a segmentação de tumores de uma forma semi-automatizada.
- realizar a segmentação dos tumores separadamente nos cortes duas dimensões.
- comparar o resultado das técnicas utilizadas apenas com o limiar de tons de cinza.
- avaliar a eficácia da técnica apenas na segmentação de tumores da região do colo uterino.

1.5 Organização do trabalho

Este documento está organizado da seguinte maneira: o capítulo 2 faz uma revisão sobre alguns trabalhos presentes na literatura que utilizam imagem de PET e de CT conjuntamente para realizar segmentação de tumores e que utilizam a análise multicritério aplicada a problemas de classificação; o capítulo 3 apresenta uma visão geral sobre o processo de segmentação de imagens, e elenca as características e funções de decisão utilizados neste trabalho; o capítulo 4 apresenta a tomada de decisão multicritério com alguns de seus métodos; o capítulo 5 apresenta o algoritmo utilizado para realizar a segmentação de imagens; o capítulo 6 apresenta os experimentos e resultados; o capítulo 7 apresenta a conclusão do trabalho e tópicos para trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

Segundo Jafar et al. (2006), tradicionalmente a segmentação de tumores pode ser feita através de dois tipos de imagens: funcionais e estruturais.

Na primeira modalidade, na qual se incluem tecnologias como a Tomografia por Emissão de Pósitrons (PET), uma dose de um radiofármaco é injetado no paciente. Tecidos com maior atividade metabólica (conseqüentemente, com maiores chances de serem tumores) absorvem uma maior quantidade do produto, o que, na imagem, resulta em regiões com sinais mais acentuados. Apesar desse grande contraste entre regiões sadias e doentes, a intensidade do sinal de absorção do fármaco pelos diversos tecidos decai gradativamente, o que dificulta o preciso delineamento dos tumores.

A categoria de imagens estruturais, na qual se incluem tecnologias como a Tomografia Computadorizada (CT) e a Ressonância Magnética (MRI), tem o objetivo de visualizar a anatomia das estruturas internas de forma detalhada. Uma das suas principais características para a identificação de tumores é a sua alta resolução espacial, que auxilia no delineamento correto das estruturas internas. A utilização das características de ambos os tipos de imagens começa a ser amplamente empregada, mostrando bons resultados para uma correta segmentação de tecidos doentes (MILLER, 2004).

Este capítulo está organizado da seguinte maneira: a seção 2.1 apresenta trabalhos presentes na literatura que utilizaram imagens de PET e de CT para realizar a segmentação de tumores, e a 2.2, trabalhos que utilizam a análise multicritério em problemas de classificação.

2.1 Segmentação de tumores utilizando informações de PET e de CT combinadas

Devido ao fato de as duas categorias de imagens anteriormente citadas trazerem informações de natureza distintas, o uso de ambas em um processo de segmentação de imagens passou a ser investigado, objetivando alcançar resultados mais precisos. Uma das combinações utilizadas para a segmentação de tumores que utilizam ambas as categorias de imagens é a tecnologia denominada PET/CT, que utiliza tanto características das imagens de PET como de imagens de CT.

A respeito dessa técnica, Jafar et al. (2006) propuseram um software de diagnóstico auxiliado por computador que simultaneamente utiliza os dados de ambas as imagens para identificação de tumores do pulmão. De acordo com os autores, é o primeiro trabalho a propor uma solução que utiliza dados integrados dessas duas espécies de imagens para segmentação. No primeiro passo, o algoritmo utiliza técnicas de limiarização e filtros no

domínio espacial para automaticamente identificar, na imagem CT, as regiões de interesse correspondentes aos pulmões. As regiões de interesse identificadas são, então, mapeadas às imagens de PET. Após o registro, o algoritmo de segmentação aplica múltiplos limiares para identificar as regiões com maiores intensidades, e, conseqüentemente, candidatas a serem tumores. Após a segmentação, para reduzir o número de falsos positivos decorrentes do processo de registro das imagens, a técnica utiliza sistemas de inferências baseadas na lógica *fuzzy*. Esses sistemas levam em consideração características como o contraste dos tumores identificados e a intensidade média dos tons de cinza dos tumores. Após a eliminação de falsos positivos, a abordagem utiliza regras baseadas em experiências clínicas para classificar o tumor segundo sua chance de realmente ser um tecido maligno. A técnica foi aplicada a um conjunto de três experimentos e os tumores identificados foram comparados com diagnósticos clínicos. O resultado alcançado foi de 75% de sensibilidade e 100% de especificidade.

Com o intuito de demonstrar a eficiência da utilização de imagens de PET e de CT conjuntamente na segmentação de tumores, Murakami et al. (2007) realizaram uma avaliação do impacto da utilização de ambas as informações combinadas para o estadiamento do câncer de cabeça e pescoço, sobretudo a mensuração do tamanho do volume do tumor. A população do estudo contou com 23 pacientes. Dois especialistas determinaram, de forma consensual, o volume dos tumores, e outros dois médicos utilizaram três técnicas diferentes para a determinação do estadiamento do câncer: empregando apenas métodos convencionais da medicina, como informações de CT ou de MRI de forma independentes; as técnicas convencionais acrescidas de informações de PET e de CT; e com o uso apenas de imagens de PET e de CT, acrescidas de informações sobre os valores das intensidades de absorção do fármaco por cada voxel. As técnicas que utilizaram imagens de PET e de CT apresentaram maiores sensibilidades e especificidades que a técnica dos métodos convencionais. Os autores concluem que o uso de imagens de PET juntamente com de CT é uma importante modalidade para o estadiamento do câncer e o planejamento do seu tratamento.

Através do uso de técnicas do domínio espacial, Potesil X. Huang (2007) propuseram uma nova forma para segmentação automatizada de tumores usando informações combinadas de PET e de CT. O método desenvolvido possui três passos. No primeiro, a técnica utiliza apenas imagem de PET, levando em consideração regiões com alta absorção de radiofármaco, identificadas por um especialista. Em seguida, algoritmos de crescimento de região detectam os voxels de maior intensidade local dentro da região de interesse selecionada. Os pontos detectados funcionam então como sementes, que guiam outro processo de crescimento de região, de forma a segmentar tumores na imagem funcional. Na segunda etapa, as regiões identificadas como tumores e as sadias são mapeadas para a imagem de CT e modelos probabilísticos são criados a partir das intensidades dos

voxels desse mapeamento, de forma a tentar categorizar se uma região é tumor ou não. No último passo, uma função de probabilidade conjunta, que leva em consideração as informações dos dois passos anteriores, é criada, de forma a afirmar se o voxel pertence ou não a uma região doente.

Muito utilizadas em segmentação de imagens, características de textura foram empregadas para a identificação de tumores em Zhang et al. (2010). No trabalho, os autores propuseram uma abordagem para a diferenciação entre tumores e regiões saudáveis dos pulmões. Devido ao fato de determinados tecidos (como regiões com inflamações) apresentarem alta absorção do fármaco utilizado em exames de PET, assim como os tumores, é necessário levar em consideração outros fatores para a segmentação das imagens. Inicialmente, as imagens de CT são segmentadas de forma a dividi-las entre regiões saudáveis e regiões de interesse (possíveis tumores). Após isso, as regiões de interesse identificadas na de CT são mapeadas para a imagem de PET, que já estão previamente co-registradas. A partir das imagens segmentadas, são extraídas características como desvio padrão, entropia e contraste, levando em consideração as informações das imagens de PET e CT. Os tumores e tecidos saudáveis são então classificados a partir das características identificadas.

Diferentemente dos demais, que realizaram experimentos empíricos, Hustinx e Lucignani (2010) apresentou uma visão geral da utilização das duas modalidades de imagens no tratamento de câncer da cabeça e pescoço, e explicou, sem realizar experimentos, como as duas imagens em conjunto podem ser efetivas ao se lidar com a doença. Segundo o autor, a utilização conjunta de imagens de PET e de CT começa a se tornar amplamente utilizada na segmentação, tratamento e monitoramento de tumores. Particularmente, o autor apresentou como aspectos importantes da utilização de ambas as imagens na mensuração do tamanho do tumor, a definição do estadiamento da enfermidade e o planejamento do tratamento.

Outra técnica bastante utilizada para a resolução de problemas de segmentação é sua modelagem como problemas de otimização. Em Han et al. (2011), foi proposto um método baseado em grafos que transforma o problema de realizar a co-segmentação em um problema de otimização de Campo Aleatório de Markov. A solução do problema modelado consiste em minimizar as diferenças de segmentação entre imagens de PET e de CT. O algoritmo garante o alcance da solução global ótima em um tempo polinomial. A proposta foi utilizada em imagens de PET e de CT co-registradas de um conjunto de dezesseis pacientes que possuíam câncer de cabeça e pescoço. A estratégia do experimento consistiu em tomar como base a demarcação dos tumores feitas manualmente por oncologistas e então compará-las aos resultados obtidos através da segmentação apenas empregando imagens de PET, apenas imagens de CT e utilizando o algoritmo proposto. O método desenvolvido pelos autores mostrou ser mais eficaz na grande maioria dos pacientes, sendo o que mais se aproximou à demarcação feita pelo especialista.

Também visando transformar o problema de segmentação em um problema de otimização, Ballangan, Wang e Feng (2011) propuseram uma técnica para segmentação de tumores de pulmão baseada em contornos ativos (*snakes*), através tanto de informações de PET como informações de CT. A técnica de co-registro desenvolvida foi aplicada sobre um conjunto de 10 amostras com tumores localizados dentro dos pulmões, de formas variadas. Os resultados do algoritmo foram então comparados com o procedimento de contorno ativo que usa apenas imagens de CT e de PET. Todos os resultados obtidos foram comparados com as delimitações feitas por especialistas. A técnica desenvolvida apresentou um maior índice de coincidência com as marcações feitas pelos clínicos, se comparadas com os outros procedimentos.

2.2 Análise Multicritério em problemas de classificação

A *Tomada de Decisão Multicritério* (MCDM) é uma categoria de tomada de decisão aplicada a problemas de decisão que possuem a presença de um conjunto de critérios de decisão (PENG; SHI, 2012). Nessa categoria, há a presença das alternativas, que consistem nas diferentes ações possíveis a serem tomadas, e de múltiplos objetivos, critérios, atributos ou características, que representam as dimensões através das quais as alternativas podem ser analisadas. A MCDM também pode ser aplicada a problemas de classificação, que visam classificar um objeto em uma entre várias categorias pré-determinadas. O processo de segmentação de tumores em imagens médicas também pode ser analisado como um problema de classificação, onde cada pixel pertencente à imagem deve ser classificado como pertencente a uma região sadia ou a uma região doente. O fato de imagens serem sinais que apresentam uma grande gama de informações diversas e, sobretudo, o fato de imagens de naturezas distintas estarem sendo utilizadas conjuntamente, encoraja o uso de técnicas de tomada de decisão multicritério em problemas de segmentação.

Um dos métodos de classificação usando a análise multicritério mais referenciados na literatura é o proposto em Yu (1992), denominado ELECTRE TRI, baseado no método ELECTRE, escrito em Roy (1968). O seu conceito básico consiste em verificar relações de preferência entre todas as alternativas, ou objetos a serem classificados, presentes no problema de classificação, a partir da comparação de cada critério separadamente. Cada alternativa é considerada como um vetor de várias componentes, cada uma medindo o desempenho dessa alternativa em relação a um critério ou atributo. O objetivo do método é realizar comparações entre as alternativas e categorizá-las de forma que o primeiro grupo do problema possua o conjunto de alternativas mais bem avaliadas e, o último grupo, o com piores avaliações. Semelhante ao ELECTRE TRI, em Massaglia e Ostanello (1991) é apresentado o método N-tomic, que também realiza comparações entre as alternativas para classificá-las em um conjunto pré-definido de nove grupos.

Em Léger (2002), foi proposto o método *TRI NOMinal bas e sur des Fonctions Crit eres* (TRINOMFC). O método consiste em criar, para cada uma das categorias pertencentes ao problema, um conjunto de protótipos a partir de dados de treinamento. A partir da criação de um índice de similaridade, as alternativas a serem classificadas são categorizadas em um dos grupos, dependendo de qual protótipo a amostra em questão mostrou-se mais similar. A função que calcula o índice de similaridade leva em consideração pesos distintos para cada critério, de acordo com a decisão do especialista. Os autores ilustram o método ao aplicá-lo na área de construção, em que tentam inferir os tipos de acidentes que cada trabalhador está mais propenso a sofrer. Cada trabalhador deveria ser classificado em um, de três grupos, representando os acidentes mais comuns: as quedas, acidentes nos olhos e cortes. Os critérios utilizados são o trabalho realizado pelo trabalhador, a sua especialidade e o tipo de construção em que estavam trabalhando.

Na área de sinais biomédicos, Goletsis et al. (2004) utilizaram o TRINOMFC para classificar batidas cardíacas através da análise de imagens de Eletrocardiograma (EGC). No trabalho, os autores visam categorizar as amostras avaliadas como sendo isquêmicas ou não. O problema é modelado a partir da criação de dois grupos (batida isquêmica e batida normal), e a identificação de cinco critérios, que são utilizados no processo de classificação. Cada um dos grupos é povoado com um conjunto de protótipos. Cada protótipo é previamente categorizado por um especialista entre batida isquêmica ou não e possui um valor para cada um dos cinco critérios avaliados. Os critérios avaliados são a idade do paciente, a amplitude da onda T do EGC, a polaridade da onda T, a amplitude do segmento ST e o declive do segmento ST. Dessa forma, o primeiro grupo contém um conjunto de amostras de batidas cardíacas isquêmicas e o outro grupo, um conjunto de amostras consideradas normais. Os autores então, a partir da definição de um índice de similaridade, categorizam as demais batidas cardíacas em um dos dois grupos, dependendo a qual protótipo a amostra em questão mostrou-se mais similar. A contribuição dos autores do trabalho foi utilizar algoritmos genéticos para a definição dos pesos de cada critério. O algoritmo busca maximizar a sensibilidade e a especificidade dos resultados. O algoritmo desenvolvido alcançou um resultado de 91% em sensibilidade e especificidade.

No trabalho Belacel (2000) é proposto um método teórico baseado na teoria *fuzzy* para o problema de classificação, denominado PROAFTN. A abordagem opera da seguinte maneira: para cada objeto do problema a ser classificado, é calculada a relação de indiferença entre o objeto e cada protótipo pertencente às categorias. A relação de indiferença significa o quão dois objetos são equivalentes (PERNY, 1998). Dessa forma, quanto maior o valor dessa relação, maior a similaridade entre os dois. Para o cálculo da indiferença, a abordagem utiliza dois conceitos presentes na literatura multicritério: a concordância e a discordância. A concordância significa o quão próximo dois objetos são em relação a cada um dos seus critérios. Dessa forma, caso a medida de um critério em dois objetos

seja o mesmo, esses objetos possuem uma concordância máxima em relação ao critério analisado. Logicamente, dependendo do problema, uma diferença entre o valor do critério desses dois objetos pode ser relevada, de forma que a concordância ainda permaneça com um valor elevado. A discordância funciona da maneira oposta, e leva em conta diferenças acentuadas entre os critérios. Ela mede o quanto os valores de um determinado critério em dois objetos são diferentes. Uma discordância máxima entre dois objetos significa que os seus valores possuem uma diferença que não pode ser tolerada, e portanto não podem ser considerados indiferentes. Esses valores de diferença máximo permitidos, tanto na concordância quanto na discordância, são configurados pelo especialista através de parâmetros. Após o cálculo da concordância e discordância de todos os critérios entre um objeto e um protótipo, é calculada a relação de indiferença final entre os dois. Os pesos que cada critério possui nesse cálculo final também é definido pelo especialista. Dessa forma, um objeto é dito pertencer a uma determinada categoria caso a relação de afinidade entre ele e qualquer protótipo dessa categoria seja a máxima encontrada em relação aos outros protótipos do problema. Os autores utilizam o PROAFTN para categorizar imagens de microscópio de leucemia em nove grupos da doença. O estudo utilizou 47 critérios, alguns aplicados a todos os grupos e outros apenas a categorias específicas, como o total de células de cada imagem, o tamanho das células e a forma dos núcleos das células. O experimento avaliou um total de 83 imagens e os resultados, depois de confrontados com a avaliação de um especialista, alcançou um índice de 96,4% de acerto.

Uma das dificuldades de se conseguir uma classificação satisfatória é a eliciação dos parâmetros utilizados nos problemas. Eles devem ser definidos de forma que se otimize o grau de precisão da classificação. Contudo, os dados muitas vezes podem estar imprecisos ou ser difícil definir eses parâmetros. Pensando nisso, os mesmos autores do PROAFTN propõe uma forma de se inferir automaticamente alguns dos parâmetros a serem utilizados no PROAFTN, de forma que a precisão do método seja otimizada (BELACEL; RAVAL; PUNNEN, 2007). A solução é buscar otimizar uma função que calcula a indiferença entre os protótipos existentes, de forma que protótipos da mesma classe alcancem um alto grau de indiferença. A técnica consiste na utilização do teorema de Chebyshev (BHATTACHARYYA, 1987) e do método *Variable Neighborhood Search* (VNS) (HANSEN; MLADENOVIC; PÉREZ, 2008), muito utilizados para solução de problemas de otimização. O método foi testado em quatro bases de doenças diferentes (câncer de mama, diabetes, doença de coração e hepatite), e visava categorizar cada uma das doenças a partir de atributos como a uniformidade das células, índice de massa muscular e idade dos pacientes. O método PROAFTN com VNS foi comparado com diversos outros classificadores, e obteve desempenho superior à grande maioria.

Ainda com o objetivo de inferir os parâmetros utilizados no método de classificação, os mesmos autores do PROAFTN propuseram diversos outros trabalhos. Em Al-Obeidat

et al. (2009), foi proposta uma abordagem baseada em algoritmos de discretização e algoritmos genéticos, e, baseando-se em 14 bases de testes diferentes, foi comparada com outros cinco classificadores. No final, o seu desempenho médio foi o segundo melhor, com uma diferença de apenas 0,09% em relação ao primeiro colocado, as redes neurais. Ainda se apoiando em algoritmos evolucionários, Al-Obeidat et al. (2010) descreve uma abordagem baseada no método *Differential Evolution* (DE), um algoritmo evolucionário proposto em Storn e Price (1997). Diferentemente dos demais métodos propostos até então, esse infere, além de outros parâmetros do PROAFTN, os pesos ótimos para cada critério, a partir do conjunto de treinamento. Ele foi aplicado a doze bases de dados diferentes, e obteve o melhor desempenho médio entre sete métodos avaliados, incluindo redes neurais. Em citeonline37, também com algoritmos de discretização, mas incrementando com a utilização de métodos de *data mining*, foi proposta uma nova forma de se inferir os parâmetros e modelar protótipos que melhor representassem cada classe do problema. O método foi aplicado a doze bases diferentes e teve o segundo melhor desempenho médio. Finalmente, em Al-Obeidat et al. (2011), foi proposto outro método para se inferir os parâmetros do PROAFTN, com o emprego do algoritmo evolucionário *particle swarm optimization* (PSO) (KENNEDY; EBERHART, 1995). O método foi aplicado a doze bases de dados e comparado com sete outros métodos de classificação, conseguindo o melhor desempenho médio em termos de precisão de acerto.

No próximo capítulo, será explicado o funcionamento geral de um método de segmentação e como os algoritmos de classificação e a tomada de decisão multicritério podem ser empregados de forma a contribuir nesse processo.

3 SEGMENTAÇÃO DE IMAGENS

O processo de segmentação consiste em particionar uma imagem em diferentes regiões, separadas por algum critério, como cor ou textura. Geralmente, a segmentação autônoma é uma das mais difíceis tarefas no processamento de imagens digitais (GONZALEZ, 2007). O resultado do processo de segmentação é um conjunto de segmentos que coletivamente formam a imagem inteira.

As técnicas de segmentação podem se basear em descontinuidade ou similiaridade. No primeiro grupo, o objetivo é particionar a imagem baseando-se em mudanças abruptas de intensidade. De forma geral, os métodos que se baseiam na descontinuidade buscam a detecção de contornos ou bordas. Entre os representantes dessa categoria, encontram-se a transformada de Hough (DUDA; HART, 1972) e métodos baseados em grafos (SHI; MALIK, 2000).

Nas técnicas de similiaridade, o objetivo é particionar a imagem em regiões que são similares em relação a algum critério. Entre os métodos mais utilizados dessa categoria incluem-se a limiarização, que consiste em se definir um valor de limiar que separa os pixels da imagem analisada em dois conjuntos: os que estão acima e os que estão abaixo desse valor. O desafio nessa abordagem é encontrar o valor de limiar que melhor divide a imagem em relação ao objetivo que se deseja alcançar. É muito utilizado quando se deseja um tempo de processamento baixo. A segmentação por limiarização também pode possuir vários valores de limiar. Dessa forma, a imagem é dividida em mais de duas partes. De forma a apoiar a limiarização, métodos baseados em histograma também podem ser usados. Neles, o histograma da imagem é construído, e o seu objetivo é detectar os pontos mais altos e baixos obtidos, de forma a guiar o processo de limiarização.

Outro método bastante utilizado na segmentação de imagens é o crescimento de região. Nele, um conjunto de pixels da imagem, denominados sementes, são pré-determinados e guiam o restante do processo de segmentação. Cada uma das sementes marcam o início de um objeto a ser segmentado. O processamento básico do algoritmo consiste em, iniciando-se pelas sementes, verificar se os seus pixels vizinhos possuem similiaridade suficiente para serem agregados àquele objeto. Caso decida-se que devem ser agregados, o mesmo teste é efetuado para os seus vizinhos, e assim sucessivamente. Tradicionalmente, o critério utilizado para decidir se um pixel deve ser englobado ou não é o tom de cinza, e o processo de classificação é simples: caso a diferença entre o tom de cinza do pixel atual e da semente não seja superior a um limiar qualquer, o pixel é agregado. A Figura 5 mostra uma imagem em que os pixels preenchidos formam um objeto, e o pixel com a esfera azul representa a semente no crescimento de região. Caso o critério a ser utilizado seja o tom de cinza, e o método de classificação assuma que os pixels devem

possuir o mesmo valor, ao final do processamento do algoritmo todos os pixels preenchidos pertencerão ao mesmo objeto.

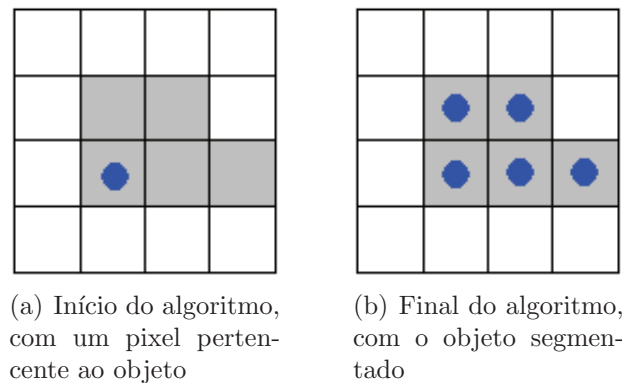


Figura 5 – Funcionamento do crescimento de região

Este trabalho utilizou o crescimento de região como método de segmentação de tumores, pois, além de ser uma técnica que possui uma alta flexibilidade para customizações, exige que um conjunto de sementes seja previamente definido. Como a segmentação de tumores em imagens biomédicas é um processo semi-automatizado, já que um especialista clínico deve indicar onde se iniciam os tumores, esse requisito é atendido.

Para que o crescimento de região alcance o seu objetivo de segmentar a imagem corretamente, essencialmente é necessária a definição de dois elementos do algoritmo. O primeiro é o conjunto de critérios que serão utilizados para se decidir se um pixel deve ser agregado a um determinado objeto ou não. O segundo é a função de decisão a ser utilizada, ou seja, dado um pixel e diversas medidas relacionadas a ele, é necessário um procedimento que determine se esse pixel faz parte ou não do objeto em questão.

As próximas seções tratam, respectivamente, do conjunto de critérios utilizados neste trabalho para guiar o processo de segmentação do crescimento de região e das funções de decisão estudadas para fazer a definição da agregação ou não de um pixel a um objeto.

3.1 Características de imagens

No campo do reconhecimento de padrões, características estruturais e de texturas muitas vezes são utilizadas para segmentar regiões de imagens, incluindo exames do tipo CT e MRI. No campo de segmentação de imagens médicas, o fato dos tecidos saudáveis e doentes apresentarem características distintas, como o tamanho e forma, podem contribuir para uma correta segmentação dos tumores, como mostrado em Yu et al. (2009). Em Zhang et al. (2010) é proposto um conjunto de 29 características a serem analisadas nas imagens de PET e de CT de forma a se tentar diferenciar cânceres do pulmão de tecidos

sadios. Este trabalho utilizou essas características como critérios a serem considerados durante o processo de classificação para guiar o processo de segmentação.

3.1.1 Características de Primeira Ordem

As características de primeira ordem são aquelas que levam em consideração os valores dos pixels isoladamente. Considerando um conjunto de n amostras, onde x_i representa a amostra de número i , as características de primeira ordem levadas em consideração no estudo são as seguintes:

- Mediana. Com os dados ordenados, caso n seja ímpar, a mediana será o elemento na posição $\frac{n+1}{2}$. Caso n seja par, é o resultado da média simples entre os elementos das posições $\frac{n}{2}$ e $\frac{n}{2} + 1$.
- média, definida como $\frac{1}{N} \sum_{i=1}^n i$.
- desvio-padrão, definido como $\sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2}$, em que μ representa a média.
- obliquidade, definida como $\frac{\sum_{i=1}^N (x_i - \mu)^3}{(N-1)\sigma^3}$, em que σ representa o desvio-padrão.
- curtose, definida como $\frac{\sum_{i=1}^N (x_i - \mu)^4}{(N-1)\sigma^4}$.

3.1.2 Características de Segunda Ordem

As características de segunda ordem levam em consideração a relação entre pares de pixels, e as utilizadas nesse trabalho foram calculadas a partir das chamadas *Spatial Grey-level Dependences Matrices* (SGLDM), também conhecidas como matrizes de co-ocorrência, propostas em Haralick, Shanmugam e Dinstein (1973). As SGLDM são matrizes que calculam quantas vezes, em uma imagem, determinados tons de cinzas aparecem como vizinhos. Essa medida é calculada tomando-se um ângulo como referência. Caso o ângulo escolhido seja 0° , a matriz mostra o número de vezes que os tons de cinza aparecem lado a lado. Caso seja 45° , quantas vezes dois tons são vizinhos considerando que um está um pixel acima e um pixel à direita, ou um pixel abaixo e um pixel à esquerda, do outro. Com 90° a matriz representa quantas vezes dois tons são vizinhos, considerando que um esteja acima ou abaixo do outro. Por exemplo, considerando a Figura 6, caso o ângulo de 0° seja usado para computação da SGLDM, a matriz resultante e a exibida na Figura 7. Nessa figura, o valor da posição (0,0) ser 4 significa que, em 4 situações, há um valor zero ao lado de outro valor zero na imagem original. O valor da posição (0,1) ser 2 significa que em 2 vezes há um valor zero ao lado de um valor 1, e assim sucessivamente.

As características analisadas através da SGLDM foram as seguintes:

- Segundo momento angular, que está relacionada à homogeneidade da imagem e é definida como $\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \left(\frac{f(i,j)}{R}\right)^2$, em que R é uma constante, $f(i,j)$ é o valor do

$$\begin{bmatrix} 0 & 0 & 1 & 1 \\ 0 & 0 & 1 & 1 \\ 0 & 2 & 2 & 2 \\ 2 & 2 & 3 & 3 \end{bmatrix}$$

Figura 6 – Matriz a partir da qual será calculada a SGLDM

$$\begin{bmatrix} 4 & 2 & 1 & 0 \\ 2 & 4 & 0 & 0 \\ 1 & 0 & 6 & 1 \\ 0 & 0 & 1 & 2 \end{bmatrix}$$

Figura 7 – Matriz SGLDM calculada a partir da Figura 6

pixel nas coordenadas (i, j) e N_g é o número de tons da imagem. Um alto valor dessa característica indica uma imagem de alta uniformidade, como uma textura uniforme.

- *sum average*, definida como $\sum_{i=2}^{2N_g} iP_{x+y}(i)$, relacionada a distribuição dos tons na imagem, onde .
- entropia, definida como $-\sum_{i=0}^{N_g} \sum_{j=0}^{N_g} f(i, j) \log(f(i, j))$, que representa a condição inversa de homogeneidade, ou seja, o quão os elementos estão desordenados.

3.1.3 Características de Alta Ordem

As características de alta ordem levam em consideração a localização de três ou mais pixels para a sua extração. As utilizadas nesse trabalho foram baseadas nas chamadas *Neighborhood Gray-tone-difference Matrix* (NGTDM), originalmente propostas em Amadasun e King (1989). As NGTDMs são matrizes colunas em que o valor do elemento de índice i , $S(i)$, é formado a partir da Equação 3.1

$$S(i) = \begin{cases} \sum |i - \bar{A}_i|, & \text{para } i \in N_i, \text{ se } N_i \neq 0 \\ 0, & \text{caso contrário,} \end{cases} \quad (3.1)$$

onde N_i é o conjunto de todos os pixels dentro da região de interesse que possui o tom de cinza i , e \bar{A}_i é calculada a partir da Equação 3.2,

$$\bar{A}_i = \bar{A}(k, l) = \frac{1}{W-1} \left[\sum_{m=-d}^d \sum_{n=-d}^d f(k+m, l+n) \right], \quad (3.2)$$

em que $(n, m) \neq (0, 0)$, $f(k, l)$ é o tom de cinza do pixel localizado nas coordenadas (k, l) , d é o tamanho da vizinhança a ser considerada como região de interesse e $W = (2d + 1)^2$. A partir da computação da NGTDM, as seguintes características são extraídas:

- *Coarseness*, que se refere à densidade dos elementos das bordas, é dada por $[\varepsilon + \sum_{i=0}^{G_h} S(i)/n]^{-1}$, em que ε é um valor pequeno para prevenir divisão por zero, G_h é o maior valor encontrado na região de interesse e n é o conjunto de pixels na região.
- contraste, que está relacionado à distribuição dos tons de cinza na imagem, e é definido como $[\frac{1}{N_g(N_g-1)} \sum_{i=0}^{G_h} \sum_{j=0}^{G_h} P_i P_j (i-j)^2] \times [\frac{1}{n} \sum_{i=0}^{G_h} S(i)]$, onde N_g é o número de tons de cinza diferentes na região de interesse e $P_i = \frac{N_i}{n}$.
- *busyness*, que é a medida da mudança de tons de cinza na região de interesse, e que é calculada através de $\sum_{i=0}^{G_h} P_i S(i) / \sum_{i=0}^{G_h} \sum_{j=0}^{G_h} |iP_i - jP_j|$. Regiões de tumores tendem a ter essa medida acentuada, já que são mais irregulares que tecidos saudáveis.

3.1.4 Características Estruturais

As características estruturais, que dizem respeito às características anatômicas das imagens, são as seguintes:

- Média do gradiente, que é a média padrão calculada sobre o gradiente da imagem, a partir da aplicação do filtro de Sobel (HADWIGER et al., 2006).
- desvio-padrão do gradiente, que é o desvio-padrão calculado sobre o gradiente da imagem.

3.1.5 Características Específicas

Outras duas características específicas de cada modalidade de imagem também foram analisadas. Para a imagem de PET, utilizou-se o *Standardized Uptake Value* (SUV) (THIE; HUBNER; SMITH, 1999), que é uma medida da quantidade de radiação encontrada em determinada parte do corpo, e calculada por meio da Equação 3.3,

$$SUV(t) = \frac{c(t)}{d/w}, \quad (3.3)$$

em que $c(t)$ é a concentração de radioatividade em um tempo t , d é a dose radioativa administrada e w é peso do paciente. Utilizou-se a média e o desvio-padrão do SUV como características.

Para a imagem CT, foi utilizado o valor da imagem normalizado para a escala Hounsfield (PATTERSON; HOROWITZ; EISNER, 1994), que é uma transformação linear da medida do coeficiente de atenuação linear original, levando em consideração a radiodensidade da água destilada nas condições normais de temperatura e pressão. Essa

transformação linear é dada pela Equação 3.4,

$$HU = 1000 \times \frac{\mu_x - \mu_{agua}}{\mu_{agua}}, \quad (3.4)$$

onde μ_x é o coeficiente de atenuação linear original e μ_{agua} é o coeficiente de atenuação linear da água destilada. Utilizou-se a mediana da imagem na escala Housnfield como característica.

3.2 Funções de decisão

O problema de classificação pode ser definido como a atribuição de um conjunto finito de alternativas a um conjunto de grupos, categorias ou classes, pré-definidos (WALLENIOUS et al., 2008). Esse conjunto de grupos são determinados por esteriótipos, e o processo de identificação consiste em realizar comparações entre o objeto desconhecido, que está sendo analisado, e o conjunto conhecido de classes, de acordo com atributos definidos (CLANCEY, 1984). Por exemplo, o processo de classificação é utilizado na identificação de um animal a partir de descrições de suas características como tamanho, cor e forma. O processo de segmentação de tumores em imagens médicas também pode ser analisado como um problema de classificação, em que cada pixel pertencente à imagem deve ser classificado como pertencente a uma região sadia ou a uma região doente.

Essa seção apresenta os métodos de classificação utilizados para realizar a segmentação multicritério dos tumores, e comparados entre si durante os experimentos. Todos os métodos de classificação apresentados possuem o mesmo objetivo e usam os mesmos dados. Dado um objeto \mathbf{x} , formando por n componentes, tal que $\mathbf{x} = \{x_1, x_2, \dots, x_n\}$, em que cada componente x_j representa a medida do objeto \mathbf{x} em relação a um critério, e um conjunto de categorias $C = \{c_1, c_2, \dots, c_k\}$, o objetivo dos métodos de classificação é, a partir de uma base de treinamento, formada por vários objetos, com suas componentes já definidas, e previamente categorizadas em uma das categorias, assinalar o objeto \mathbf{x} como pertencente a uma das categorias.

3.2.1 k -NN

O *Nearest Neighbor* (NN) é uma técnica para classificação de objetos baseada em outros objetos de treinamento previamente classificados, a partir da proximidade entre o novo experimento a ser categorizado e os demais (COVER; HART, 1967). Dado o indivíduo \mathbf{x} , o NN procura inferir a qual categoria do conjunto C ele pertence, levando em consideração todo o conjunto de elementos previamente categorizados. Nessa fase de classificação, a técnica verifica qual elemento do conjunto de treinamento possui as

componentes mais próximas às do indivíduo a ser categorizado e atribui a ele sua categoria correspondente. Usualmente, utiliza-se a distância Euclidiana como medida de distância, apesar de ser possível utilizar outras métricas, como o *cityblock* (KRAUSE, 1986) ou a distância de *hamming* (HAMMING, 1950).

O k -NN é uma variante do NN, que difere no fato de usar um número maior de vizinhos para classificar a nova amostra. Esse número de vizinhos a ser levado em consideração é definido pelo parâmetro k . Um exemplo gráfico de classificação com o k -NN é mostrado na Figura 8. Nela, tem-se duas classes conhecidas - a formada pelas esferas azuis e a formada pelas esferas vermelhas -, e quer-se classificar o elemento representado pela esfera verde. Caso o parâmetro k seja definido como 3, a técnica irá tomar, como regra de classificação, os três vizinhos mais próximos ao novo elemento (esses vizinhos foram delimitados pelo círculo de linha contínua). O indivíduo será então classificado como pertencente à categoria de esferas vermelhas, já que ela possui dois representantes. Contudo, caso o parâmetro k seja definido como 5, os 5 primeiros vizinhos mais próximos serão levados em consideração (delimitados pelo círculo de linha pontilhada), de forma que a classificação atribuída seria a de esferas azuis - 3 elementos contra 2. Em problemas de classificação onde só haja dois grupos definidos, deve-se definir o parâmetro k como sendo um número ímpar, de forma que se evite a ocorrência de empate (HALL; PARK; SAMWORTH, 2008).




Figura 8 – Exemplo de classificação utilizando o k -NN

3.2.2 LDA

Segundo FISHER (1936), a análise de discriminante linear (LDA) é uma técnica de classificação que visa encontrar uma combinação linear formada pelas características dos objetos, de forma que se consiga caracterizar o maior número de indivíduos nas suas respectivas classes de forma correta. Considerando como exemplo um problema com

duas classes conhecidas e que cada objeto é formado por duas características, pode-se representar os dados em formato de matriz, como na Figura 9, onde os dois conjuntos de dados representam os dados de treinamento das duas classes.

$$\text{Conjunto 1} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \\ \dots & \dots \\ a_{n1} & a_{n2} \end{bmatrix} \quad \text{Conjunto 2} = \begin{bmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \\ \dots & \dots \\ b_{n1} & b_{n2} \end{bmatrix}$$

Figura 9 – Exemplo de matriz usada no LDA

A LDA computa inicialmente a média de cada conjunto separadamente e a média de todo o conjunto de dados. A partir do cálculo de m_1 e m_2 , que representam, respectivamente, as médias do conjunto 1 e 2, pode-se obter a média de todos os dados, m_3 , a partir de uma soma ponderada entre as outras duas, dependendo de qual a probabilidade de um objeto pertencer a um dos dois conjuntos. A partir do cálculo dessas médias, são obtidos índices de dispersão inter-classes e entre-classes. O objetivo da LDA é então maximizar o índice de dispersão inter-classes e minimizar os índices intra-classes, de forma a se alcançar a combinação linear que melhor define os dois conjuntos.

3.2.3 Naive Bayes

De acordo com Domingos e Pazzani (1997), o classificador *Naive Bayes* se caracteriza pelo fato de considerar que todos os atributos que descrevem um objeto são condicionalmente independentes, ou seja, a probabilidade de uma variável assumir um determinado valor não é influenciada pela probabilidade das demais. Contudo, esse método se apresenta como um dos mais eficientes algoritmos para classificação (ZHANG, 2004). Uma vantagem desse classificador é o fato de necessitar de um pequeno conjunto de dados de treinamento para estimar os parâmetros necessários para a classificação.

Para se classificar uma nova amostra \mathbf{x} , o classificador *Naive Bayes* trabalha calculando a probabilidade *a posteriori* de cada classe c do problema dado que se conhece o indivíduo, conforme a Equação 3.5, desenvolvida a partir da aplicação do Teorema de Bayes (MCGRAYNE, 2012):

$$P(c|X) = \frac{p(c)p(X|c)}{p(X)} \quad (3.5)$$

O denominador da equação pode ser desconsiderado, visto que ele não é impactado por qualquer classe, apenas pelo elemento a ser categorizado, de forma que é constante

para todas as classes pertencentes ao conjunto C . O elemento $p(c)$ é a probabilidade *a priori* da classe c ocorrer, definida pela porcentagem de indivíduos na base de treinamento pertencentes à classe em questão. Como o classificador assume que os eventos são condicionalmente independentes, o termo $p(X|c)$, que geralmente é uma medida associada à vizinhança do elemento \mathbf{x} , pode ser calculada de acordo com a Equação 3.6:

$$P(X|c) = p(x_1, x_2, \dots, x_N) = \prod_{i=1}^n p(x_i|c) \quad (3.6)$$

O classificador *Naive Bayes* atribui ao objeto \mathbf{x} a classe cuja probabilidade *a posteriori* foi a maior encontrada, conforme a Equação 3.7:

$$P(c|X) \propto p(c) \prod_{i=1}^n p(x_i|c) \quad (3.7)$$

4 TOMADA DE DECISÃO MULTICRITÉRIO

A tomada de decisão multicritério (MCDM) é uma categoria de tomada de decisão aplicadas a problemas de decisão que possuem a presença de um conjunto de critérios de decisão (PENG; SHI, 2012). Nessa categoria, há a presença das alternativas, que consistem nas diferentes ações possíveis a serem tomadas, e múltiplos objetivos, critérios, atributos ou características, que representam as dimensões através das quais as alternativas podem ser analisadas.

À medida que o número de critérios aumenta, conflitos entre eles podem aparecer. É o caso de atributos que são conflituosos, como, por exemplo, o preço de comercialização de um produto, que pode apresentar conflito com o lucro total esperado. Diferentes atributos podem também apresentar unidades ou métricas distintas, como, por exemplo, o preço de um produto e o número de dias de utilização de um peça. De forma a tentar solucionar o problema de decisão, frequentemente são aplicados pesos aos objetivos, de forma que se busque preferenciar os que possuem pesos maiores em detrimento àqueles com pesos menores.

Problemas de tomada de decisão multicritério podem ser expressos em formato de uma matriz $\mathbf{A}(M \times N)$, em que M representa o número possível de alternativas, e N , os critérios a serem analisados (ZIMMERMANN, 1991). Dessa forma, cada elemento a_{ij} representa o desempenho da alternativa A_i quando avaliada em termos do critérios C_j . É também assumido que os pesos W_j de cada atributo foram previamente definidos (W_j , $j = 1, \dots, N$). A Figura 10 apresenta uma representação gráfica dessa matriz.

Critérios →	C1	C2	C3	...	C _N
Alternativas ↓	W_1	W_2	W_3	...	W_N
A_1	a_{11}	a_{12}	a_{13}	...	a_{1N}
A_2	a_{21}	a_{22}	a_{23}	...	a_{2N}
A_3	a_{31}	a_{32}	a_{33}	...	a_{3N}
...
A_M	a_{M1}	a_{M2}	a_{M3}	...	a_{MN}

Figura 10 – Matriz representando as alternativas, pesos e critérios em um problema de tomada de decisão multicritério

4.1 Métodos de tomada de decisão multicritério

4.1.1 WSM

O *Weighted Sum Model* é o mais antigo e provavelmente o mais utilizado método de tomada de decisão multicritério. Considerando um problema de M alternativas e N

critérios, a melhor alternativa é aquela que satisfaz à Equação 4.1:

$$A_{WSM} = \max_i \sum_{j=1}^N q_{ij} \times W_j, \text{ para } i = 1, 2, 3, \dots, M \quad (4.1)$$

A_{WSM} representa o valor da melhor alternativa, q_{ij} é o valor da alternativa i em relação ao critério j e W_j é o peso do critério j . Dessa forma, o WSM busca, dentre as alternativas possíveis, aquela que maximiza o resultado final ao efetuar o somatório de cada critério multiplicado por seu respectivo peso, em cada alternativa. O WSM é utilizado facilmente quando a unidade de medida de todos os critérios é igual. Contudo, quando os critérios apresentam unidades distintas, o processo torna-se mais complexo.

Um exemplo de resolução com o WSM é apresentado na Figura 11, considerando a matriz **A** da Figura 11 e os pesos $W1 = 0,10$, $W2 = 0,10$, $W3 = 0,30$ e $W4 = 0,40$.

$$A = \begin{bmatrix} 25 & 20 & 15 & 30 \\ 10 & 30 & 20 & 30 \\ 30 & 10 & 30 & 10 \end{bmatrix}$$

Figura 11 – Matriz representando um problema multicritério

O valor da alternativa 1 será $25 \times 0,1 + 20 \times 0,2 + 15 \times 0,3 + 30 \times 0,4 = 23$.

O valor da alternativa 2 será $10 \times 0,1 + 30 \times 0,2 + 20 \times 0,3 + 30 \times 0,4 = 25$.

O valor da alternativa 3 será $30 \times 0,1 + 10 \times 0,2 + 30 \times 0,3 + 10 \times 0,4 = 18$.

Dessa forma, a alternativa 2 é selecionada como vencedora, pois possui o maior resultado.

4.1.2 WPM

Segundo Miller e Starr (1969), o WPM é similar ao WSM, com a diferença de que há multiplicações ao invés de adições. No WPM, os critérios são comparados uns com os outros de forma a se calcular o mais eficiente. Essa comparação é feita através da Equação 4.2:

$$R(A_K/A_L) = \prod_{j=1}^N (a_{Kj}/a_{Lj})^{W_j} \quad (4.2)$$

em que A_K e A_L representam as alternativas K e L , N é o número de critérios, a_{Kj} e a_{Lj} são os valores do critério j em relação às alternativas k e l , e W_j é o peso do critério j .

Considerando a Figura 11, utilizada no exemplo anterior, a aplicação do WPM

resultaria em:

$R(A1/A2) = (25/10)^{0,1} \times (20/30)^{0,2} \times (15/20)^{0,3} \times (30/30)^{0,4} = 0,92$. Ou seja, A1 é inferior a A2.

$R(A1/A3) = (25/30)^{0,1} \times (20/10)^{0,2} \times (15/30)^{0,3} \times (30/10)^{0,4} = 1,42$. Ou seja, a alternativa A1 é superior a A3.

$R(A2/A3) = (10/30)^{0,1} \times (30/10)^{0,2} \times (20/30)^{0,3} \times (30/10)^{0,4} = 1,53$. Ou seja, a alternativa A2 é superior a A3.

Dessa forma, a alternativa A2 apresenta-se como vencedora. O WPM possui a vantagem de poder ser usado onde as unidades de medida são diferentes. Porém, apresenta apenas valores relativos, e não absolutos.

4.2 Classificação Multicritério

De acordo com Clancey (1984), diversas abordagens distintas podem ser utilizadas para a solução de problemas de classificação, como soluções estatísticas, tal como a análise discriminante, e técnicas não-paramétricas, como redes neurais e aprendizado de máquina. A maior diferença entre essas abordagens e a tomada de decisão multicritério (MCDM) em soluções de problemas de classificação é que a segunda considera, no desenvolvimento do seu modelo de solução, as preferências de um especialista, bem como de suas políticas de julgamento. Isso faz com que a teoria multicritério possa apresentar alternativas adaptadas às diferenças presentes nos problemas em que será aplicada.

Os métodos de classificação multicritério podem ser divididos em dois grupos: paramétricos e não-paramétricos (YEVSEYEVA, 2007). O primeiro grupo reúne abordagens que permitem a construção de modelos com as quais o especialista pode interagir através da definição de parâmetros. Os parâmetros dessas abordagens devem ser bem definidos, pois é a partir deles que o especialista irá expor suas preferências com relação aos critérios e alternativas presentes no problema. São integrantes desse grupo os métodos baseados em função de utilidade e baseados em relação de prioridade. Abordagens não-paramétricas são compostos por métodos baseados em regras que assumem que o comportamento do especialista é complexo de se modelar através de parâmetros, mas que é possível fazê-lo a partir de um conjunto de regras. Como exemplo, há os métodos baseados em conjuntos *fuzzy* (NOVÁK IRINA PERFILIEVA, 1999) e *rough sets* (PAWLAK, 1982).

Outra forma de divisão dos métodos de classificação multicritério é a proposta por Zopounidis e Doumpos (2002). Nessa forma, há duas situações no problema de classificação: classificação ordinal e nominal. Na primeira, o conjunto de grupos, ou categorias, presentes no problema são organizados de forma hierárquica, de forma que haja uma

relação de preferência entre eles. Para se modelar essa classificação, tem-se, além dos grupos, um valor de referência para a fronteira superior e outro para a fronteira inferior de cada grupo. Dessa forma, um objeto é dito pertencente a uma determinada categoria se, após se atribuir um valor a ele, a partir dos valores de cada um dos seus critérios, o valor atribuído ao objeto estiver dentro dessas fronteiras. Como exemplo, pode-se tomar a avaliação de estudantes a partir de conceitos escolares. Cada grupo do problema representaria um conceito (ótimo, bom, regular, ruim, péssimo), de forma que há hierarquia entre eles. Além disso, o valor do estudante pode ser calculado a partir da média aritmética de todas as suas notas (que representam os atributos). Os valores de fronteira seriam, por exemplo, para o grupo 'Ótimo', os valores 100 e 90. Dessa forma, um aluno só seria classificado como pertencente ao grupo 'Ótimo' se possuísse seu valor entre 90 e 100.

Na classificação nominal, não há relação hierárquica entre as categorias, de forma que não há relação de preferência. Cada uma das categorias é povoada, então, por protótipos. Cada protótipo consiste em um objeto previamente categorizado em cada um dos atributos do problema, normalmente coletado de uma base de treinamento. Um objeto avaliado é dito pertencente a uma categoria caso se assemelhe mais com os protótipos pertencentes à categoria em questão. Um exemplo é a definição de doenças a partir de sintomas detectados. Os grupos do problema representariam as doenças disponíveis, os critérios seriam os sintomas identificados e os objetos a serem avaliados seriam os pacientes a serem categorizados. Dessa forma, não há hierarquia entre os grupos. O problema de classificação de pixels em uma imagem pode ser categorizado como um problema de classificação nominal, já que há duas classes disponíveis (pixels sadios e pixels doentes) que não possuem hierarquia entre elas.

4.2.1 PROAFTN!

O *PROcédure d'Affectation Floue pour la problématique du Tri Nominal*, proposto em Belacel (2000), é um método que visa solucionar a problemática da ordenação nominal em problemas multicritério. Baseado na lógica *fuzzy*, ele busca definir um grau de relação entre o objeto a ser classificado e as classes pertencentes ao problema. Ele se baseia nos princípios de concordância e discordância, discutidos em Perny (1998). O PROAFTN utiliza as seguintes notações para a resolução do problema de classificação:

- $A \rightarrow$ conjunto de objetos a serem categorizados.
- $F = \{g_1, g_2, \dots, g_n\} \rightarrow$ conjunto de n critérios a serem avaliados para classificação.
- $C = \{c_1, c_2, \dots, c_k\} \rightarrow$ conjunto de classes do problema, tal que $k \geq 2$.
- $B_h \rightarrow$ conjunto de protótipos da categoria h , em que $B_h = \{b_i^h \mid h = 1, \dots, k, i = 1, \dots, L_h\}$, onde b_i^h designa o protótipo número i da categoria h .
- $B \rightarrow$ conjunto de todos os protótipos, de todas as classes;

- $\hat{A} \rightarrow$ união dos conjuntos A e B , ou seja, $\hat{A} = A \cup B$.
- $W \rightarrow$ conjunto de pesos associados a cada critério em cada classe, tal que $W = \{w_j^h \mid j = 1, \dots, n, h = 1, \dots, k\}$, em que o elemento w_j^h designa o valor do peso do critério j quando analisado na classe h .

Cada objeto no conjunto \hat{A} é avaliado em relação aos critérios pertencentes ao conjunto F , tal que $\forall a \in \hat{A}$, $g(a) = (g_1(a), g_1(a), \dots, g_n(a))$, em que $g(a)$ é a avaliação global do objeto a , e $(g_1(a), g_1(a), \dots, g_n(a))$ é a avaliação do objeto sob cada critério isoladamente. A notação $a \in c_h$ indica que o objeto a foi classificado como pertencente à categoria c_h .

4.2.1.1 Relação de concordância

O método PROAFTN trabalha calculando a relação de indiferença entre cada objeto a ser categorizado e os protótipos do problema. Como discutido anteriormente, a relação de indiferença na lógica *fuzzy* representa o quanto dois objetos são equivalentes, de forma que, quanto maior o seu valor, maior a semelhança entre os objetos (PERNY, 1998). Para realizar o cálculo de indiferença entre dois objetos, o PROAFTN utiliza cálculos de concordância e discordância. A discordância representa o quão semelhantes dois objetos são em função dos seus critérios, e a relação de discordância representa o quão diferentes eles são. O PROAFTN calcula inicialmente relações de concordância parciais, e as agrega para calcular o índice global de concordância. Os valores de concordância parciais são calculados separadamente, um para cada critério do problema. Dessa forma, esses índices parciais representam o quão indiferente um objeto é em relação a outro, em relação a um critério específico.

Geralmente os valores de cada atributo g_j de cada um dos protótipos são representados em forma de intervalos. Assim, cada atributo de cada protótipo é associado a um intervalo $[S_j^1(b_i^h), S_j^2(b_i^h)]$, de forma que $S_j^2(b_i^h) \geq S_j^1(b_i^h)$. O valor de concordância parcial de um objeto a a um protótipo b_i^h em função de um critério j é dado conforme a Equação 4.3:

$$aI_j b_i^h \Leftrightarrow g_j(a) \in [S_j^1(b_i^h), S_j^2(b_i^h)] \quad (4.3)$$

I_j representa a relação de concordância entre dois objetos em função do critério j . Devido à imprecisão dos dados obtidos, geralmente utilizam-se dois pequenos valores, $d_j^-(b_i^h)$ e $d_j^+(b_i^h)$, cada um associado a um protótipo, para minimizar essa imperfeição, de forma que o protótipo passa a possuir o intervalo $[S_j^1(b_i^h) - d_j^-(b_i^h), S_j^2(b_i^h) + d_j^+(b_i^h)]$. Formalmente, três situações são possíveis ao se calcular a relação de concordância parcial entre um objeto e um protótipo:

- Caso $S_j^1(b_i^h) \leq g_j(a) \leq S_j^2(b_i^h)$, o objeto a é considerado totalmente concordante ao protótipo b_i^h em função do critério j . Assim, a relação de concordância assume o seu valor máximo, que é igual a 1.
- caso $g_j(a) \leq S_j^1(b_i^h) - d_j^-(b_i^h)$ ou $g_j(a) \geq S_j^2(b_i^h) + d_j^+(b_i^h)$, então a não possui concordância com o protótipo b_i^h em relação ao critério j . O valor de concordância nessa situação é 0.
- caso $S_j^1(b_i^h) - d_j^-(b_i^h) \leq g_j(a) \leq S_j^1(b_i^h)$ ou $S_j^2(b_i^h) \leq g_j(a) \leq S_j^2(b_i^h) + d_j^+(b_i^h)$, então há uma fraca concordância entre os dois objetos. Nesse caso, a relação de concordância assume um valor entre 0 e 1.

Sendo $C_j(a, b_i^h)$ o índice de concordância parcial entre um objeto e um protótipo em relação a um critério j , seu valor pode ser calculado através da Equação 4.4.

$$C_j(a, b_i^h) = \min\{C_j^-(a, b_i^h), C_j^+(a, b_i^h)\}, \quad (4.4)$$

$$C_j^-(a, b_i^h) = \frac{\varepsilon_1 - \min\{S_j^1(b_i^h) - g_j(a), \varepsilon_1\}}{\varepsilon_1 - \min\{S_j^1(b_i^h) - g_j(a), 0\}} \quad (4.5)$$

$$C_j^+(a, b_i^h) = \frac{\varepsilon_2 - \min\{g_j(a) - S_j^2(b_i^h), \varepsilon_2\}}{\varepsilon_2 - \min\{g_j(a) - S_j^2(b_i^h), 0\}} \quad (4.6)$$

A partir do cálculo de n relações de concordância parciais, uma para cada critério do problema, é possível calcular o índice global de concordância entre um objeto e um protótipo, formado a partir da multiplicação dos índices parciais, ponderados por seus respectivos pesos, conforme a Equação 4.7.

$$C_I = \sum_{j=1}^n (w_j^h \times C_j(a, b_i^h)) \quad (4.7)$$

Cada peso w_j^h representa a importância dada pelo especialista do problema ao critério em uma classe específica. Dessa forma, caso $w_j^h = 0$, isso significa que o critério j não possui nenhuma importância dentro da classe h . Se $w_j^h = 1$, o critério j é o único que deve ser levado em consideração no momento de se analisar a concordância entre um objeto e os protótipos da classe h .

4.2.1.2 Relação de discordância

Além do cálculo da concordância, o PROAFTN utiliza o conceito de discordância para a classificação de um objeto em uma classe. O índice de discordância parcial $D_j(a, b_i^h)$ entre um objeto a e o protótipo b_i^h significa o quão discordantes estão os seus valores em

relação ao critério j . Para o cálculo da discordância parcial, é introduzido o conceito de *veto-threshold*. Para cada protótipo, existem dois *veto-threshold*: $v_j^+(b_i^h)$ representa o mínimo valor aceito para a diferença $g_j(a) - S_j^2(b_i^h)$. Analogamente, o *veto-threshold* $v_j^-(b_i^h)$ representa o mínimo valor aceito para a diferença $S_j^1(b_i^h) - g_j(a)$. A partir disso, três situações podem ocorrer:

- Caso $S_j^1(b_i^h) - d_j^-(b_i^h) \leq g_j(a) \leq S_j^2(b_i^h) + d_j^+(b_i^h)$, então não há discordância entre o protótipo e o objeto em função do critério j , e a discordância parcial é 0.
- caso $g_j(a) \leq S_j^1(b_i^h) - v_j^-(b_i^h)$ ou $g_j(a) \geq S_j^2(b_i^h) + v_j^+(b_i^h)$, então a diferença mínima aceitável foi ultrapassada, e há discordância total entre o objeto e o protótipo em função do critério j . Isso significa que, mesmo que para os outros critérios haja uma indiferença máxima, o fato de a discordância ser também máxima para o critério j implica que os dois não podem ser considerados indiferentes.
- caso $S_j^1(b_i^h) - v_j^-(b_i^h) \leq g_j(a) \leq S_j^1(b_i^h) - d_j^-(b_i^h)$ ou $S_j^2(b_i^h) + v_j^+(b_i^h) \leq g_j(a) \leq S_j^2(b_i^h) + d_j^+(b_i^h)$, há uma fraca discordância entre o objeto e o protótipo. Nesse caso, a relação de discordância parcial assume um valor entre 0 e 1.

A relação parcial de discordância $D_j(a, b_i^h)$ pode então ser calculada através da equação 4.8.

$$D_j(a, b_i^h) = \max\{D_j^-(a, b_i^h), D_j^+(a, b_i^h)\}, \quad (4.8)$$

$$D_j^-(a, b_i^h) = \frac{g_j(a) - \max\{g_j(a), S_j^1(b_i^h) - \varepsilon_1\}}{\varepsilon_1 - \max\{S_j^1(b_i^h) - g_j(a), v_j^-(b_i^h)\}} \quad (4.9)$$

$$D_j^+(a, b_i^h) = \frac{g_j(a) - \min\{g_j(a), -S_j^2(b_i^h) + \varepsilon_2\}}{-d_j^+(b_i^h) + \max\{-S_j^2(b_i^h) + g_j(a), v_j^+(b_i^h)\}} \quad (4.10)$$

A partir dos cálculos de discordância parciais, pode-se calcular o índice de discordância global, dado pela Equação 4.11.

$$D_I(a, b_i^h) = 1 - \prod_{j=1}^n (1 - D_j(a, b_i^h))^{w_j^h} \quad (4.11)$$

4.2.1.3 Relação de indiferença

A partir dos índices globais de concordância e discordância, é possível calcular a relação de indiferença entre um objeto a e um protótipo b_i^h , conforme a Equação 4.12.

$$I(a, b_i^h) = \left(\sum_{j=1}^n (w_j^h \times C_j(a, b_i^h)) \right) \times \left(\prod_{j=1}^n (1 - D_j(a, b_i^h))^{w_j^h} \right) \quad (4.12)$$

A indiferença leva em consideração tanto a concordância quanto a discordância. Dessa forma, mesmo que a concordância entre um objeto e um protótipo for muito alta, caso a discordância seja máxima, eles não são considerados nem levemente indiferentes. Isso é um mecanismo utilizado em casos onde um valor alto de diferença entre dois objetos em relação a um único critério pode comprometer significativamente a semelhança entre eles.

Cada classe c no conjunto C é representada por um conjunto B^h de L^h protótipos, $B^h = b_1^h, b_2^h, \dots, b_{L^h}^h$, considerados uma boa representação da classe c . Para realizar a classificação de um novo objeto a , o PROAFTN realiza os seguintes passos:

- Através da Equação 4.12, o cálculo de indiferença é calculado entre o objeto a e todos os protótipos de todas as classes.
- o grau de afinidade entre o objeto a e uma classe c é o máximo grau de indiferença calculado entre o objeto a e os protótipos pertencentes à classe c .
- o objeto a é categorizado como pertencente à classe cujo grau de afinidade foi o maior encontrado.

Uma das maiores dificuldades ao se utilizar o PROAFTN é realizar a definição dos parâmetros utilizados no seu funcionamento, como as fronteiras dos intervalos de cada protótipo, pesos de cada critério e *veto-thresholds*. Um especialista muitas vezes pode não estar disponível ou não ter experiência suficiente, o domínio do problema pode ser desconhecido ou o número de parâmetros pode ser tão grande que torne inviável a definição de todos eles. Devido a esses obstáculos, procedimentos automatizados de definição dos parâmetros foram propostos, de forma a extraí-los de dados reais já coletados.

Em Al-Obeidat et al. (2010), foi proposto, pelos mesmos autores do PROAFTN um mecanismo para extrair esses parâmetros baseados em um algoritmo evolucionário denominado *Differential Evolution* (DE), escrito em Storn e Price (1997). O método foi denominado DERPRO. A técnica utiliza um conjunto de dados previamente coletado, denominado conjunto de testes. O objetivo é encontrar os parâmetros que maximizem a eficácia da classificação após classificar novamente o conjunto de testes e comparar a classe encontrada com a classe previamente atribuída.

4.2.2 *Differential Evolution*

O *Differential Evolution* (DE) é um algoritmo evolucionário que usa operações de *crossover*, mutação e seleção para encontrar o indivíduo que apresenta o melhor valor

quando processado por uma função, denominada função de custo. Basicamente, durante a fase de inicialização, deve ser definida uma população $X = \{x_1, x_2, \dots, x_N\}$ de N vetores, consistindo cada um de D parâmetros aleatoriamente inicializados. Após isso, os elementos dessa população, denominados indivíduos, passam por operações de mutação, *crossover* e seleção de forma se encontrar o indivíduo mais apto.

Após a inicialização da população, é realizada a operação de mutação para cada vetor x_i pertencente a X , gerando um vetor mutante através da Equação 4.13,

$$v_i = x_{r1} + F \cdot (x_{r2} - x_{r3}), \quad (4.13)$$

em que x_{r1} , x_{r2} e x_{r3} são elementos pertencentes à população inicial, de forma que os três, além de x_i , sejam distintos, e F pertença ao intervalo $[0, 2]$, de forma a controlar a variação da população.

Para aumentar a diversidade dos parâmetros dos vetores, é realizado o processo de *crossover*. Nele, é definido um vetor chamado *trial-vector*, tendo suas componentes formadas pela combinação dos elementos dos vetores mutante e x_i , de forma aleatória. Uma vez gerado o *trial-vector*, o resultado da sua função de custo é comparado com a função de custo do elemento x_i . Caso apresente um melhor resultado, o *trial-vector* substitui o lugar do indivíduo x_i no conjunto de elementos da população. Quando todos os elementos do conjunto X são processados, uma nova geração é alcançada. Geralmente o processamento termina quando se alcança um número fixo de gerações ou quando, após um número pré-determinado de iterações, o melhor indivíduo encontrado não tenha sido atualizado.

4.2.2.1 DERPRO

A técnica denominada DERPRO visa encontrar os seguintes parâmetros para o PROAFTN com o *Differential Evolution*: $S_j^1(b_i^h)$, $S_j^2(b_i^h)$, $d_j^-(b_i^h)$, $d_j^+(b_i^h)$ e w_j^h , em que $j = 1, \dots, n$ é o critério e $h = 1, \dots, k$ é a classe do problema. Dessa forma, cada indivíduo pertencente à população é composto por um número de componentes igual a $5kn$, onde n é o número total de critérios e k , o número total de classes do problema. A função de custo aplicada no DERPRO utiliza um conjunto de treinamento formado por objetos já previamente categorizados em alguma das classes do problema. O procedimento aplicado é o seguinte:

- Quando um novo indivíduo na população é gerado, ele é utilizado para se computar a relação de indiferença entre os objetos no conjunto de teste e os protótipos formados pelos seus parâmetros, conforme a Equação 4.12.
- Cada objeto do conjunto de teste é então associado a uma classe, de acordo com os

resultados obtidos na relação de indiferença.

- Após essa nova classe ser definida, ela é comparada com a classe real do objeto, já que todos já estavam previamente categorizados. Caso as classes sejam a mesma, os parâmetros definidos acertaram a classificação. Caso contrário, a classificação foi mal-sucedida.
- O resultado da função de custo é a porcentagem de objetos corretamente classificados, ou seja, a função de custo é definida pela razão entre o número de objetos classificados corretamente e o número de objetos no conjunto de treinamento.

5 MÉTODO MULTICRITÉRIO DE SEGMENTAÇÃO DE IMAGENS PET/CT

O método utilizado neste trabalho para a segmentação de tumores em imagens de PET e de CT tomou como base o crescimento de região, descrito na seção 3. Ele foi adaptado de forma que utilizasse, como função de decisão, os métodos de tomada de decisão multicritério PROAFTN, k -NN, *Naive Bayes* e a análise de discriminante linear (LDA), descritos nos capítulos anteriores. Os critérios utilizados para guiar o processo de classificação foram as características da imagens apresentadas no Capítulo 3.1. Usou-se o *Differential Evolution*, descrito no Capítulo 4.2.2.1, para inferir os parâmetros utilizados no PROAFTN.

O método desenvolvido está descrito em alto nível no Algoritmo 1.

Algoritmo 1: Algoritmo multicritério de segmentação PET/CT

Entrada: (*sementesTumor*, *sementesNaoTumor*).

```

1 início
2   para CADA SEMENTE s EM SEMENTES_TUMOR E SEMENTES_NAO_TUMOR faça
3     | s.caracteristicas = calculaCaracteristicas(s);
4     (prototipos, pesos) = derpro(sementesTumor, sementesNaoTumor);
5     Pilha p = nova Pilha();
6     p.empilhar(sementesTumor);
7     enquanto P NÃO É VAZIA faça
8       | Pixel px = p.topo;
9       | px.percorrido = verdadeiro;
10      para CADA VIZINHO v DE PX faça
11        | se v.PERCORRIDO = FALSO E
12          | TESTAFUNCAODECISAO(PX,v,PROTOTIPOS) então
13            | | v.classe = px.classe;
14            | | p.empilhar(v);
14 fim

```

O algoritmo recebe como entrada dois conjuntos de pixels. O primeiro (*sementesTumor*) representa um conjunto de sementes que se tem certeza de se tratar de um tumor, enquanto o segundo (*sementesNaoTumor*) representam uma região que se tem certeza não se tratar de um tumor. Ambos os tipos de sementes são definidos pelo especialista médico, e cada um possui a propriedade *classe* definida com um valor diferente. Tipicamente, há somente duas classes no algoritmo: a classe tumor e a classe não-tumor. Para cada uma dessas sementes são calculadas as características descritas na seção 3.1, a partir da aplicação de uma máscara, tendo como pixel central a semente. Quando todas as sementes tiverem suas características computadas, o algoritmo DERPRO é chamado, caso o classificador a ser utilizado seja o PROAFTN (linha 4). Ele recebe como parâmetro o conjunto

de sementes e retorna o conjunto de protótipos que irão guiar a análise multicritério do PROAFTN, além dos pesos atribuídos a cada critério do problema.

Após isso, todas as sementes que representam região de tumor são empilhadas. Enquanto a pilha utilizada no algoritmo não está vazia, cada pixel é desempilhado da estrutura e um marcador é definido como verdadeiro, de forma a indicar que aquele elemento já foi processado. Todos os vizinhos do pixel em questão são então tomados para análise. Caso algum deles ainda não tenha sido processado, ou seja, ainda não faz parte de nenhum objeto da imagem, e a função de decisão informe que esses dois pixels são compatíveis (linha 11), esse vizinho é inserido na pilha e a ele é atribuído a mesma classe do pixel que havia sido desempilhado. Ou seja, ele é categorizado como pertencente ao tumor, e ele agora deve ser empilhado para a continuação da expansão do objeto em formação.

O algoritmo que realiza a função de decisão para indicar se o pixel em análise faz parte de uma região doente varia dependendo da técnica a ser utilizada (k -NN, LDA, *Naive Bayes* ou PROAFTN). No caso do PROAFTN, seu funcionamento é mostrado em alto nível no Algoritmo 2.

Algoritmo 2: PROAFTN

Entrada: $(px, v, prototipos, pesos)$.

```

1 início
2   maximaIndiferenca = 0;
3   classeMaximaIndiferenca = 0;
4   para CADA CASSE C DO PROBLEMA faça
5     para CADA PROTÓTIPO P DA CLASSE C faça
6       ind = indiferenca(v, p, pesos);
7       se ind > maximaIndiferenca então
8         maximaIndiferenca = ind;
9         classeMaximaIndiferenca = c;
10  se PX.CLASSE = CLASSEMAXIMAINDIFERENCA então
11    retorna VERDADEIRO;
12  senão
13    retorna FALSO;
14 fim

```

O PROAFTN inicia o seu processamento iterando sobre todas as classes pertencentes ao problema (tipicamente duas no caso de segmentação de tumores), e depois sobre todos os protótipos pertencentes àquela classe. É calculada então a relação de indiferença entre cada protótipo e o objeto a ser avaliado, e a máxima indiferença encontrada, bem como a classe do protótipo que proveu esse valor são armazenados (linhas 8 e 9). No final, caso a classe cuja maior indiferença encontrada seja igual à classe do pixel que serviu como

base da análise, é então definido que os dois elementos fazem parte do mesmo objeto. Caso contrário, eles são distintos, e o pixel analisado não é considerado como pertencente a um tumor.

O cálculo da indiferença, mostrado na linha 6 do Algoritmo 2 é calculado baseando-se nos princípios de concordância e discordância, explicados na seção 4.2.1, e funciona de acordo com o Algoritmo 3.

Algoritmo 3: indiferença

Entrada: $(v, p, pesos)$.

```

1 início
2   concordancia = concordancia(v, p, pesos);
3   discordancia = discordancia(v, p, pesos);
4   retorna  $CONCORDANCIA \times |(1 - discordancia)|$ ;
5 fim

```

A relação de indiferença é calculada a partir do cálculo da relação de concordância e discordância entre o objeto e o protótipo, mostrados nos Algoritmos 4 e 5, respectivamente.

Algoritmo 4: concordancia

Entrada: $(v, p, pesos)$.

```

1 início
2   concordanciaTotal = 0; para CADA CRITÉRIO J DO PROBLEMA faça
3     calcular a concordância parcial c em função do critério j;
4     concordanciaTotal = concordanciaTotal + (peso do criterio j × c);
5   retorna CONCORDANCIA TOTAL;
6 fim

```

O cálculo da concordância funciona calculando, para cada critério do problema, o índice de concordância parcial entre o objeto e o protótipo, levando em consideração apenas esse critério (linha 3). Esse cálculo é descrito na Equação 4.4. Após os cálculos, o índice global de concordância é retornado.

Algoritmo 5: discordancia

Entrada: $(v, p, pesos)$.

```

1 início
2   discordanciaTotal = 1; para CADA CRITÉRIO J DO PROBLEMA faça
3     calcular a discordância parcial d em função do critério j;
4     concordanciaTotal = concordanciaTotal + (peso do criterio j × c);
5   retorna CONCORDANCIA TOTAL;
6 fim

```

Analogamente ao cálculo da concordância, no cálculo da discordância são computados primeiramente os índices parciais, levando em consideração cada critério isoladamente

(linha 3). Esse cálculo é descrito na Equação 4.8. Após os cálculos, o índice global de discordância é retornado. Os métodos PROAFTN, textitDifferential Evolution e crescimento de regiões foram implementados utilizando o Matlab versão R2010a; os demais classificadores foram testados a partir de implementações já existentes no próprio Matlab.

6 EXPERIMENTOS E RESULTADOS

6.1 Aquisição e pré-processamento

Inicialmente, foram adquiridos conjuntos de exames de PET, de CT e de MRI de pacientes distintos do sexo feminino. As imagens de MRI foram adquiridas usando um *scanner 1.5 Tesla superconducting magnet (Symphony, Siemens Medical Systems, Erlangen, Germany)* que cobriu o abdômen e a pélvis com protocolos idênticos. Todos os pacientes receberam 20 ml de gel intravaginal aplicado através de seringa, e jejuaram durante quatro horas antes do exame. O protocolo de aquisição das imagens de ressonância magnética foi realizado com sequência axial em spin-echo T1-pesado, com repetição tempo/tempo eco (TR/TE) 5.2/2.6 ms, espessura de corte de 3 a 5 mm, espaçamento 0, matrix 512x512, FOV de 38 cm; sequência nos planos sagital, coronal e axial com spin-eco rápido T2-pesado utilizando grade de fase, TR/TE 4500-5000/95-116 ms, espessura de corte de 3 mm, espaçamento de 0,2 mm, matrix 512x512, FOV de 25cm; sequência no plano axial spin eco turbinada T2 com supressão de gordura, TR/TE 4500-5000/95-116 mm, espessura de corte de 5 mm, espaçamento de 0,2 mm, matrix 512x512, FOV de 30-45cm; e sequência no plano axial com spin-eco T1-pesada antes e após a administração endovenosa de gadolínio (0,1mmol/kg) TR/TE 5,2/2,6 ms, espessura de corte de 3 mm, espaçamento de 0, matrix 512x512, FOV de 35 cm.

Para a aquisição dos exames de PET e de CT, todos os pacientes fizeram jejum de pelo menos seis horas antes da aplicação da dose do radiofármaco $^{18}\text{F} - \text{FDG}$ (783,5 ± 102,3MBq). Os níveis de glicemia foram medidos antes da aplicação. O escaneamento foi executado 60 minutos após a injeção do $^{18}\text{F} - \text{FDG}$ usando um *scanner Biograph 2 PET/CT (CT: Somatom sensation 2, PET: LSO crystal, Siemens Medical Solution, Erlangen, Germany)* com um campo de visão axial de 162mm. As imagens foram obtidas com os pacientes na posição supinada. Para as imagens de CT, processamento de correção de atenuação e registro anatômico foram executados com os seguintes parâmetros: 130 kV, 25 mAs, 0,8s por rotação e espessura de corte de 5,0mm. As imagens de CT foram reconstruídas em uma matriz com resolução de 512x512 pixels. As imagens de PET foram obtidas com uma resolução de 128x128 pixels.

De forma a guiar o restante dos experimentos, as imagens de MRI foram registradas às imagens de CT. Para a aplicação do registro, utilizou-se o algoritmo de mínimo erro quadrático (ORCHARD, 2007) a partir da marcação de quatro pontos de controle por um especialista médico. Os pontos de controle marcados foram os seguintes: acetábulo do fêmur direito, cabeças dos fêmures direito e esquerdo e tronco maior do fêmur direito. O especialista médico então segmentou manualmente os tumores identificados nas imagens de MRI adquiridas de forma a servir para a validação dos resultados obtidos

pelos algoritmos analisados.

6.2 Experimentos

Cada um dos cortes dos exames de PET, de CT e de MRI, previamente registradas, e que continham tumores segmentados manualmente por um especialista médico, foram analisadas separadamente, o que totalizou um conjunto de testes de 77 imagens com tumores do colo de útero. O algoritmo de crescimento de região foi então aplicado a cada uma das imagens, variando a função de decisão utilizada no seu funcionamento (k -NN, LDA, *Naive Bayes* e PROAFTN). Devido ao fato de a etapa de otimização do algoritmo do PROAFTN ser não-determinística, uma vez que utiliza um algoritmo evolucionário com aleatoriedade, ele foi executado cinco vezes sobre cada imagem e utilizou-se a média aritmética das execuções nas métricas coletadas. O parâmetro k , do k -NN, foi setado como 1.

A segmentação, utilizando o método crescimento de região com cada uma das funções de decisão, foi executada sobre as seguintes modalidades de imagens: de PET, analisada isoladamente, de PET e de CT, analisadas simultaneamente, e de PET e de MRI, também tomadas de forma simultânea. A imagem de CT não foi analisada separadamente, pois testes preliminares apontaram que os seus resultados seriam bastante insatisfatórios. Para as três modalidades de imagens, foram coletadas as características de média, mediana, desvio-padrão, obliquidade, curtose, segundo momento angular, *sum average*, entropia, *coarseness*, contraste e *busyness*. Adicionalmente, para as imagens de PET também foram analisadas as características de mediana e desvio-padrão do SUV, além da média e desvio-padrão do gradiente. Para as imagens de CT, utilizou-se também a média da medida HU coletada, além da média e desvio-padrão do gradiente. As características de cada pixel foram coletadas aplicando-se uma máscara quadrada de dimensão 7x7, com o pixel a ser analisado na posição central.

Além da variação nas modalidades de imagens utilizadas para guiar a segmentação (PET, PET/CT e PET/MRI), investigou-se também o impacto do número de sementes iniciais no resultado final do processamento. Para isso, cada elemento do conjunto de testes, para cada uma das combinações de categoria de imagens utilizadas, foi processado considerando o fornecimento de 4, 6, 8 ou 10 sementes iniciais. As sementes foram escolhidas de forma aleatória, a partir da marcação manual feita pelo especialista médico, sendo metade de sementes de tumor e metade de sementes de regiões sadias.

Considerando o número de imagens processadas no conjunto de testes (77), o número de combinação de modalidades de imagens utilizadas (3) e o número de combinações de sementes (4), cada uma das quatro técnicas foi executada 924 vezes. Considerando também o fato de que o PROAFT foi executado cinco vezes para cada teste, a fim de se buscar

a média das execuções, ele foi responsável por 4620 execuções. O número de execuções no total foi de 7392. Os testes foram executados no Matlab versão R2010a.

Além disso, as mesmas 77 imagens foram segmentadas através do crescimento de região tradicional, que utiliza a diferença entre os tons de cinza de pixels vizinhos para delimitar a região do tumor. Para isso, foi selecionada uma semente de tumor aleatória, que pertencia à região segmentada manualmente pelo especialista. O limiar para funcionamento do algoritmo foi o valor anterior àquele que fazia o algoritmo selecionar mais pixels que o número marcado pela segmentação manual. O método foi executado de cinco formas distintas: apenas com imagens de PET, de CT e de MRI, e combinando-se a imagem de PET com de CT e de PET com de MRI. A combinação entre modalidades de imagens foi feita a partir da aplicação da operação lógica *and* em cada pixel. Dessa forma, um pixel no resultado gerado pela combinação PET/CT só seria marcado como sendo um tumor caso ele tenha sido considerado uma região doente tanto na imagem de PET quanto na de CT.

Analisou-se nos experimentos as medidas de sensibilidade e relação de falsos positivos de cada teste executado, e tomou-se como referência a marcação manual executada pelo especialista clínico. A primeira métrica diz respeito à quantidade de pixels marcados, tanto pelo método quanto pelo especialista, em função de todos os pixels marcados manualmente. A relação de falsos positivos, por outro lado, diz respeito ao número de pixels não marcados como doentes pelo especialista, porém assinalados como tumores pelo método avaliado. Um teste ótimo resultaria em uma sensibilidade de 1 e em uma taxa de falsos positivos de 0.

6.3 Resultados

As Figuras 1, 2 e 3 mostram os resultados médios obtidos para os valores de sensibilidade e falsos positivos. Cada um dos gráficos diz respeito a uma combinação de tipos de imagens utilizadas na segmentação (PET, PET/CT, PET/MRI), mostrando os resultados alcançados pelas quatro técnicas que utilizaram multicritério para a resolução do problema. Os mesmos resultados também foram representados em forma de tabela, na imagem 12. O gráfico representado na Figura 4, por sua vez, mostra o desempenho médio alcançado pelo crescimento de região com a diferença entre os tons de cinza dos pixels.

A combinação de imagens de PET e de MRI foi a que alcançou os maiores valores médios de sensibilidade e a de PET foi a melhor colocada em função da relação de falsos positivos. Esse resultado é factível, pois a ressonância magnética é a categoria de imagem que apresenta maior qualidade em termos dos sinais obtidos. Contudo, também é possível notar que a combinação de imagens PET/CT ficou em segundo lugar em função da sensibilidade, tendo um desempenho inferior de apenas 1,3% em relação à sensibilidade




Gráfico 1 – Resultado da segmentação multicritério de tumores utilizando imagem de PET




Gráfico 2 – Resultado da segmentação multicritério de tumores utilizando imagens de PET e CT

média obtida pelo conjunto PET/MRI. Isso indica que, apesar de a imagem de CT possuir sinais de qualidade inferior, sua combinação com a imagem de PET pode trazer resultados aproximados àqueles obtidos com a ressonância magnética. Adicionalmente, observou-se também que, para o conjunto de testes utilizado, a combinação de duas categorias de imagens (PET/CT ou PET/MRI) trouxe ganhos em relação à utilização da imagem PET de forma independente em função de sensibilidade. Quão maior foi o grau de sensibilidade de




Gráfico 3 – Resultado da segmentação multicritério de tumores utilizando imagens de PET e MRI

Imagem/técnica		Sensibilidade	Falso positivo
PET	KNN	0,68	1,58
	LDA	0,69	1,48
	NAIVE BAYES	0,77	2,78
	PROAFTN	0,64	2,06
PET/CT	KNN	0,72	2,77
	LDA	0,75	2,64
	NAIVE BAYES	0,76	2,53
	PROAFTN	0,67	2,62
PET/MRI	KNN	0,75	2,38
	LDA	0,73	1,74
	NAIVE BAYES	0,76	2,26
	PROAFTN	0,67	2,98

Figura 12 – Resultado da segmentação multicritério de tumores

uma técnica, maior foi a uma relação de falsos positivos. Isso aconteceu porque, à medida que assinala mais pixels como tumores (aumentando a sensibilidade), pode acontecer de também marcar pixels que não são doentes (aumento da relação de falsos positivos). O resultado de PET mostra isso: foi a pior classificada em função de sensibilidade, porém foi a melhor colocada em função dos falsos positivos.

A Figura 5 mostra o desempenho médio dos classificadores multicritérios avaliados,

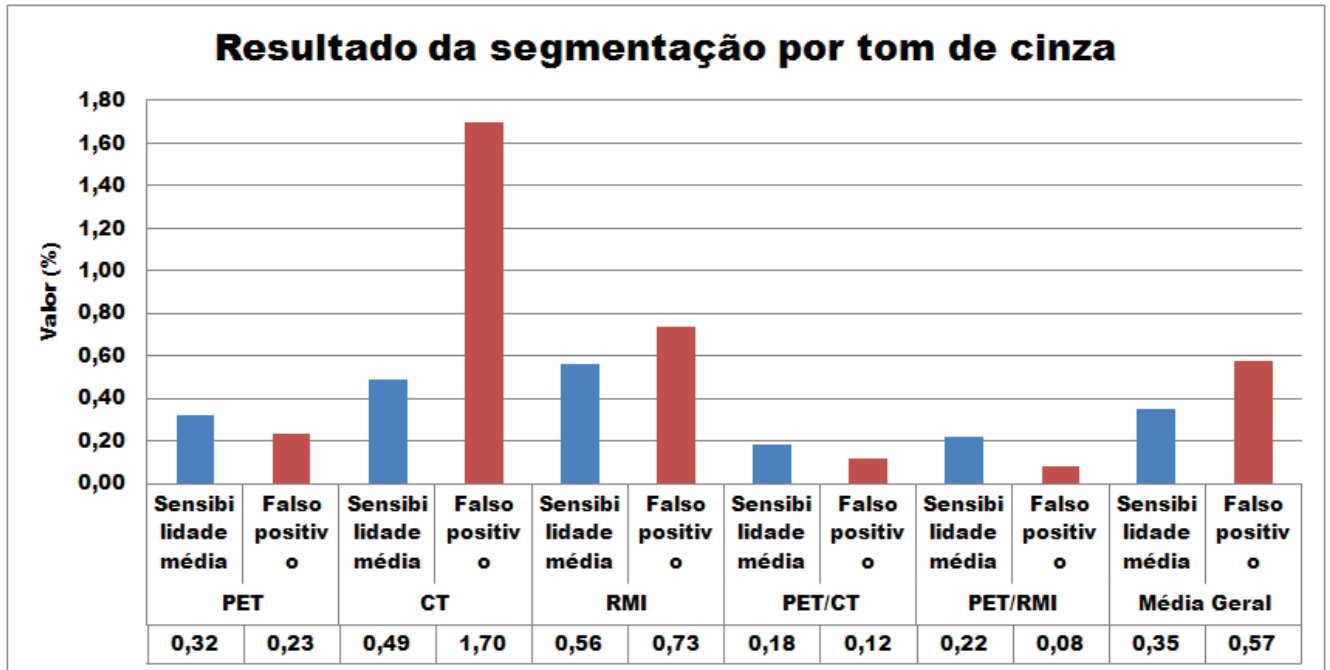


Gráfico 4 – Resultado da segmentação de tumores utilizando limiar de tons de cinza

independentemente do tipo de imagem utilizada na segmentação. Os resultados indicaram que, em termos de sensibilidade, o melhor classificador foi o *Naive Bayes*, seguido por LDA e *k*-NN e LDA, empacados, e depois pelo PROAFTN. A diferença entre os primeiros e último classificado é de 8,3%. A última colocação do PROAFTN pode ser explicada pelo seu fator de aleatoriedade, que muitas vezes pode não ser efetivo.

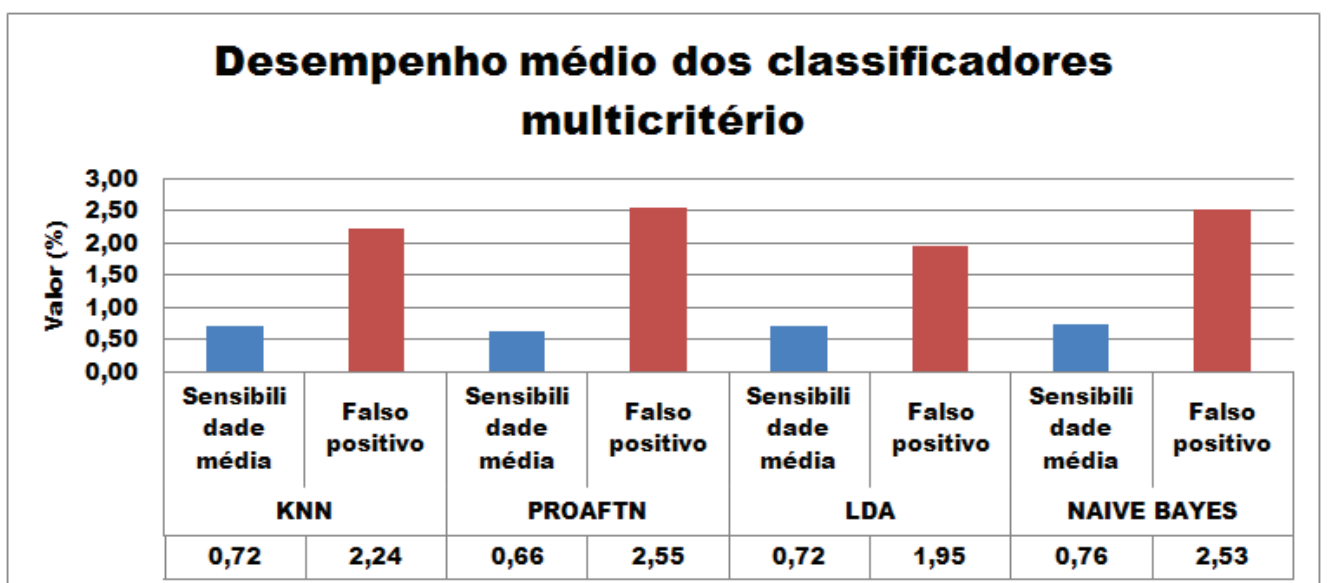


Gráfico 5 – Desempenho médio das técnicas de multicritério na segmentação de tumores

Três exemplos de imagens segmentadas são mostradas nas Figuras 13, 14 e 15. As segmentações utilizando as técnicas são mostradas em um contorno amarelo e a marcação do especialista médico é representada como uma região verde. A primeira imagem mostra um tumor segmentado com 95% de sensibilidade utilizando-se o conjunto PET/RMI. A segunda, uma segmentação com 96% de sensibilidade utilizando-se a combinação PET/CT. A última figura, por sua vez, mostra uma segmentação que alcançou 87% de sensibilidade, porém claramente apresenta uma segmentação errada, possuindo uma taxa de falsos positivos muito alta. O resultado ruim pode ser explicado quando se destaca a região segmentada apenas na imagem de PET. Isso é representado na Figura 16. Como a bexiga do paciente está muito próxima ao tumor, na imagem PET isso parece representar um único elemento. As características da imagem de PET influenciaram fortemente a segmentação, ignorando as propriedades da imagem de CT. Esse comportamento pode ter sido influenciado pelos pesos atribuídos às características das imagens de PET. Além disso, percebe-se que as imagens de MRI e de PET não estão perfeitamente registradas, o que pode ter sido determinante para o erro apresentado.




Figura 13 – Imagem segmentada com 95% de sensibilidade utilizando PET e MRI (traço amarelo) sobre a imagem de MRI




Figura 14 – Imagem segmentada com 96% de sensibilidade na PET e CT (traço amarelo) sobre a imagem de MRI

Quando os resultados dos classificadores multicritério são comparados com os da solução por limiar de tons de cinza, no gráfico 4, mostra-se que seus resultados mostraram valores mais satisfatórios em termos de sensibilidade. A solução multicritério alcançou valores de sensibilidade médios superiores em mais de 15% em relação à solução tradicional do crescimento de região, para todas as três combinações de imagens utilizadas (PET, PET/CT e PET/MRI). Contudo, em termos da relação de falsos positivos, o tom de cinza




Figura 15 – Imagem segmentada com 87% de sensibilidade na PET e CT (traço amarelo) sobre a imagem de MRI




Figura 16 – Imagem segmentada com 87% de sensibilidade na PET/CT sobre a imagem de PET (traço amarelo)

apresentou um valor mais satisfatório. Isso pode ser explicado pela forma que a limiarização foi aplicada: foi escolhido o valor de limiar anterior àquele em que a segmentação englobasse mais pixels que o tamanho do tumor marcado pelo especialista. Como muitas vezes as bordas dos tumores possuem diferenças pequenas de intensidade, um valor um pouco maior de limiar pode significar englobar muito mais pixels. Com o limiar escolhido, muitas vezes o crescimento de região marcou poucos pixels, sendo que o valor imediatamente subsequente marcaria muitos pixels não pertencentes ao tumor.

O baixo desempenho da solução de segmentação por limiar de tons de cinza em termos de sensibilidade pode ser explicado também pela grande dependência que esta técnica possui em relação à semente aleatoriamente escolhida, já que leva em consideração apenas pixels adjacentes. Além disso, os experimentos mostraram que, para determinados tipos de imagens, essa técnica é ainda mais ineficiente. Em exames que possuem uma área parecida com um degradê, por exemplo, apesar do fato de os pixels de lados opostos dessa região possuírem uma diferença grande de tons de cinza, eles seriam marcados como pertencentes ao mesmo objeto, visto que é analisada apenas a relação entre dois vizinhos imediatos. A decisão multicritério aplicada, por outro lado, leva em consideração uma região de 49 pixels para fazer a análise.

Outro resultado obtido é a sensibilidade e taxa de falsos positivos médias em função do número de sementes aleatoriamente definidas, mostrado na Figura 6. Pode-se notar que, para os experimentos realizados, a diferença entre o pior resultado obtido de sensi-

bilidade (4,6 e 10 sementes) foi 1,4% inferior ao melhor (8 sementes). Isso mostra que as técnicas avaliadas não apresentaram grandes variações em função do número de sementes utilizadas no início do processo de segmentação. Contudo, a taxa de falsos positivos foi melhorada à medida que o número de sementes aumentou.




Gráfico 6 – Desempenho médio em função da quantidade de sementes utilizadas

Os testes realizados foram validados estatisticamente a partir do emprego do teste *t* de *Student* pareado. Os resultados de todos os testes dos classificadores multicritérios tomados dois a dois são apresentados na Figura 17, com a aplicação de um nível de confiança de 95%. A Figura 18 mostra o resultado dos testes considerando os tipos de imagens utilizados (PET, PET/CT, PET/MRI) e a técnica multicritério empregada. Novamente, foi utilizado um nível de confiança de 95%.

	PROAFTN	LDA	NAIVE BAYES
KNN	<0,001	0,895	0,005
PROAFTN		<0,001	<0,001
LDA			0,006

Figura 17 – Resultado do teste *t* para os classificadores multicritério

6.4 Considerações finais

Os resultados obtidos mostraram que as técnicas que utilizaram múltiplos critérios no processo de segmentação de tumores do colo uterino apresentaram desempenho superior

KNN	PET - PET/CT	<0,001
	PET - PET/RM	<0,001
PROAFTN	PET - PET/CT	0,038
	PET - PET/RM	0,002
NAIVE BAYES	PET - PET/CT	0,024
	PET - PET/RM	0,010
LDA	PET - PET/CT	<0,001
	PET - PET/RM	<0,001

Figura 18 – Resultado do teste t em função do tipo de imagem utilizada

em relação ao crescimento de região baseado no limiar de tons de cinza em termos de sensibilidade. Além disso, a utilização combinada do conjunto de imagens de PET e de CT mostrou desempenho superior àquela que utilizou apenas a imagem de PET e muito próximo da combinação de PET e MRI. Contudo, em relação à taxa de falsos positivos, a solução utilizando limiar por tons de cinza ainda foi superior.

Outro aspecto analisado foi o impacto do número de sementes utilizadas no início do processo de segmentação. Os resultados apontaram que, variando-se o número de sementes (4, 6, 8 ou 10), o resultado médio de sensibilidade obteve uma variação inferior a 2%, porém a relação de falsos positivos decaiu à medida que o número de sementes aumentou.

O valor de sensibilidade obtido pode ter sido influenciado pela forma que as imagens foram obtidas e pré-processadas, já que as imagens de ressonância magnética tiveram que ser registradas para se adequarem às imagens CT. Como o processo do registro de imagens não é perfeito, erros podem ter sido propagados durante essa fase. Além disso, a marcação do especialista médico também está sujeita a variações e imprecisões, como qualquer procedimento manual.

7 CONCLUSÃO E TRABALHOS FUTUROS

Este trabalho buscou investigar a utilização de técnicas de tomada de decisão multicritério como solução para o problema de segmentação de tumores em imagens médicas. Além disso, procurou estudar se a utilização conjunta de exames de tomografia por emissão de pósitrons (PET) e de tomografia computadorizada (CT) poderia contribuir para a solução do problema.

Quatro algoritmos de classificação foram utilizados para levarem em consideração múltiplos critérios: k -nn, PROAFTN, Análise de Discriminante Linear (LDA) e Naive Bayes. Imagens de tumores da região do colo uterino foram segmentadas pelas quatro técnicas e seus resultados comparados com a segmentação manual efetuada por um especialista médico. De forma complementar, a segmentação utilizando apenas diferença de tons de cinza de pixels vizinhos também foi efetuada e os resultados dos experimentos foram comparados.

Vinte e nove características das imagens foram utilizadas como critérios de decisão da tomada de decisão multicritério. Como as imagens foram segmentadas pelo especialista clínico originalmente nos exames de ressonância magnética (MRI), foi necessário a aplicação de um registro entre elas e as imagens de PET e de CT para tornar possível comparação entre a segmentação dos métodos e o delineamento feito pelo especialista. Como o registro de imagens é um procedimento passível de falhas, as precisões dos resultados podem ter sido reduzidas.

Os experimentos demonstraram que as segmentações efetuadas pelos algoritmos utilizando tomada de decisão multicritério foram superiores, em termos de sensibilidade, àquelas efetuadas utilizando-se apenas a diferença de tons de cinza em mais de 15%. Em termos de relação de falsos positivos, o limiar de tons de cinza apresentou resultado superior. Além disso, concluiu-se também que a segmentação utilizando imagens conjuntas de PET e de CT apresentou resultados superiores àquelas que utilizaram apenas imagens de PET, e bastante próximas à utilização de PET e de MRI conjuntamente.

7.1 Trabalhos Futuros

Como tópicos para trabalhos futuros, incluem-se:

- a escolha de um sub-conjunto das características utilizadas que possam maximizar a sensibilidade da segmentação efetuada, visto que a diminuição de critérios de classificação pode significar a melhoria dos resultados;
- a investigação de outros classificadores no processo de segmentação;

- a utilização de tamanhos de máscaras diferentes da utilizada neste trabalho (7x7) no momento da coleta das características de cada pixel;
- a utilização de pesos distintos para cada critério nos algoritmos k -nn, LDA e Naive Bayes;
- a comparação com outros métodos de segmentação;
- o estudo dos casos em que as características da imagem de PET foram levadas em consideração em detrimento das demais;
- o estudo de formas de se diminuir a taxa de falsos positivos da segmentação;
- a comparação dos resultados obtidos com a segmentação manual efetuada por mais de um especialista médico, de forma a se buscar diminuir a variação das marcações;
- o estudo de formas mais precisas de registro de imagens, de forma a se buscar minimizar os erros provenientes desse processo;
- avaliar os métodos utilizados em função do tempo de execução.

REFERÊNCIAS

International Atomic Energy Agency. The role of pet/ct in radiation treatment planning for cancer patient treatment. In: IAEA-TECDOC. **Proceedings...** [S.l.], 2007.

AL-OBEIDAT, Feras et al. **Differential Evolution for learning the classification method PROAFTN**. Knowledge-Based Systems, v. 23, n. 5, p. 418-426, 2010. ISSN 0950-7051. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0950705110000250>>

AL-OBEIDAT, Feras et al. **An evolutionary framework using particle swarm optimization for classification method PROAFTN**. Applied Soft Computing, v. 11, n. 8, p. 4971-4980, 2011. ISSN 1568-4946. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1568494611002213>>.

AL-OBEIDAT, Feras et al. Discretization techniques and genetic algorithm for learning the classification method proaftn. In: MACHINE LEARNING AND APPLICATIONS, 2009. ICMLA '09. INTERNATIONAL CONFERENCE ON. **Proceedings...** [S.l.], 2009. p. 685–688.

AMADASUN, Moses; KING, Robert. **Textural features corresponding to textural properties**. Systems, Man and Cybernetics, IEEE Transactions on, v. 19, n. 5, p. 1264-274, 1989. ISSN 0018-9472.

AMETAMEY, Simon M.; Honer, Michael; SCHUBIGER, Pius A. Molecular imaging with pet. In: CENTER FOR RADIOPHARMACEUTICAL SCIENCE OF ETH, PSI AND USZ, Zurich, Switzerland. **Proceedings...** [S.l.], 2008.

BALLANGAN, Cherry et al. Lung tumor delineation in pet-ct images based on a new segmentation energy. In: NUCLEAR SCIENCE SYMPOSIUM AND MEDICAL IMAGING CONFERENCE (NSS/MIC). **Proceedings...** [S.l.], 2011. p. 3202-3205. ISSN 1082-3654.

BELACEL, Nabil. **Multicriteria assignment method PROAFTN: Methodology and medical application**. European Journal of Operational Research, v. 125, n. 1, p. 175-183, 2000. ISSN 0377-2217. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0377221799001927>>.

BELACEL, Nabil; RAVAL, Hiral B.; PUNNEN, Abraham. P. **Learning multicriteria fuzzy classification method PROAFTN from data**. Comput. Oper. Res., Elsevier Science Ltd., v. 34, n. 7, p. 1885-1898, 2007. ISSN 0305-0548. Disponível em: <<http://dx.doi.org/10.1016/j.cor.2005.07.019>>.

BHATTACHARYYA, Boissy. **One sided chebyshev inequality when the first four moments are known**. Communications in Statistics - Theory and Methods, v. 16, n. 9, p. 2789-2791, 1987. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/03610928708829540>>.

CLANCEY, William J. **Classification Problem Solving**. Springer US, p. 31, 1984.

COVER, T.; HART, P. **Nearest neighbor pattern classification.** Information Theory, IEEE Transactions on, v. 13, n. 1, p. 21-27, 1967. ISSN 0018-9448.

DOMINGOS, Pedro; PAZZANI, Michael. **On the Optimality of the Simple Bayesian Classifier under Zero-One Loss.** Mach. Learn., Kluwer Academic Publishers, Hingham, MA, USA, v. 29, n. 2-3, p. 103-130, 1997. ISSN 0885-6125. Disponível em: <<http://dx.doi.org/10.1023/A:1007413511361>>

DUDA, Richard O.; HART, Peter. E. **Use of the Hough transformation to detect lines and curves in pictures.** Commun. ACM, ACM, New York, NY, USA, v. 15, n. 1, p. 11-15, 1972. ISSN 0001-0782. Disponível em: <<http://doi.acm.org/10.1145/361237.361242>>.

FISHER, Ronald A. **The use of multiple measurements in taxonomic problems.** Annals of Eugenics, Blackwell Publishing Ltd, v. 7, n. 2, p. 179-188, 1936. ISSN 2050-1439. Disponível em: <<http://dx.doi.org/10.1111/j.1469-1809.1936.tb02137.x>>.

GOLETISIS, Yorgos et al. **Automated ischemic beat classification using genetic algorithms and multicriteria decision analysis.** Biomedical Engineering, IEEE Transactions on, v. 51, n. 10, p. 1717-1725, oct. 2004. ISSN 0018-9294.

GONZALEZ, Rafael. C; Woods, Richard E. **Digital Image Processing**, 3. ed, [S.l.]: Massachussetts:Addison-Wesley Publishing Company inc, 2007.

HADWIGER, Markus et al. **Real-time Volume Graphics.** Natick, MA, USA: A. K. Peters, Ltd., 2006. ISBN 1568812663.

HALL, Peter et al. **Choice of neighbor order in nearest-neighbor classification.** Annals of Statistics 2008, Vol. 36, No. 5, p. 2135-2152, 2008.

HAMMING, Richard W. **Error detecting and error correcting codes.** BELL SYSTEM TECHNICAL JOURNAL, AMER TELEPHONE TELEGRAPH CO, NEW YORK, v. 29, n. 2, p. 147-160, 1950. ISSN 0005-8580.

HAN, Dongfeng et al. Globally optimal tumor segmentation in pet-ct images: a graph based co-segmentation method. In: 22ND INTERNATIONAL CONFERENCE ON INFORMATION PROCESSING IN MEDICAL IMAGING. **Proceedings...** Springer Verlag, 2011. (IPMI'11), p. 245-256. ISBN 978-3-642-22091-3. Disponível em: <<http://dl.acm.org/citation.cfm?id=2029686.2029711>>.

HANSEN, Pierre; MLADENOVIC, Nenad; MORENO PÉREZ, José A. **Variable neighbourhood search: methods and applications.** 4OR, Springer-Verlag, v. 6, p. 319-360, 2008. ISSN 1619-4500. Disponível em: <<http://dx.doi.org/10.1007/s10288008-0089-1>>.

HARALICK, Robert M.; SHANMUGAM, Kasiviswanathan; DINSTEN, Its'hak. **Textural Features for Image Classification.** Systems, Man and Cybernetics, IEEE Transactions on, SMC-3, n. 6, p. 610 -621, nov. 1973. ISSN 0018-9472.

HUSTINX, Roland; LUCIGNANI, Giovanni. Pet/ct in head and neck cancer: an update. In:

EUROPEAN JOURNAL OF NUCLEAR MEDICINE AND MOLECULAR IMAGING. **Proceedings...** [S.l.], 2010.

JAFAR, Iyad. et al. Computerized detection of lung tumors in pet/ct images. In: ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, New York. **Proceedings..** [S.l.], 2006. p. 2320-2323. ISSN 1557-170X.

KENNEDY, James; EBERHART, Russell. Particle swarm optimization. In: IEEE INTERNATIONAL CONFERENCE ON. **Proceedings...** [S.l.], 1995. v. 4, p. 1942 1948 vol.4.

HENNEL, Jacek W.; KLINOWSKI, Jacek. Fundamentals of nuclear magnetic resonance. In: LONGMAN SCIENTIFIC & TECHNICAL - ESSEX. **Proceedings...** [S.l.], 1993.

KRAUSE, Eugene. **Taxicab Geometry: An Adventure in Non-Euclidean Geometry.** [S.I.]: Dover Publications, 1986. ISBN 9780486252025. Disponível em: <<http://books.google.com.br/books?id=IW7ICV0QXWwC>>.

LÉGER, Julien; MRTEL, Jean-Marc. **A multicriteria assignment procedure for a nominal sorting problematic.** European Journal of Operational Research, v. 138, n. 2, p. 349-364, 2002. ISSN 0377-2217. MCDA Methodologies for Classification and Sorting. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S037722170100251X>>.

MASSAGLIA, Roberto; OSTANELLO, Anna. N-tomic: a support system for multicriteria segmentation problems. **Proceedings...** [S.I.]: Springer Verlag, LNEMS 356, Berlin, 1991. p. 167-174.

MCGRAYNE, Sharon B. **The Theory That Would Not Die: How Bayes' Rule Cracked the Enigma Code, Hunted Down Russian Submarines, and Emerged Triumphant from Two Centuries of Controversy.** [S.I.]: Yale University Press, 2012.

MILLER, David.; STARR, Martin K. **Executive decisions and operations research.** [S.I.]: Prentice-Hall, Inc., Englewood Cliffs, 1969.

MILLER, Janet C. Pet/ct for tumor imaging. In: RADIOLOGY ROUNDS. **Proceedings...** [S.I.], 2004.

MURAKAMI, Ryu et al. Impact of fdg-pet/ct imaging on nodal staging for head-and neck squamous cell carcinoma. In: INTERNATIONAL JOURNAL OF RADIATION ONCOLOGY BIOLOGY PHYSICS. **Proceedings...** [S.I.], 2007.

NOVÁK, Vilém; PERFILIEVA, Irina; MOČKOŘ, Jiří. **Mathematical Principles of Fuzzy Logic.** [S.I.]: Springer, 1999.

ORCHARD, Jeff. **Efficient Least Squares Multimodal Registration With a Globally Exhaustive Alignment Search.** Image Processing, IEEE Transactions on, v. 16, n. 10, p. 2526-2534, 2007. ISSN 1057-7149.

PATTERSON, Randolph E. et al. **Comparison of modalities to diagnose coronary artery**

disease. Seminars in Nuclear Medicine, v. 24, n. 4, p. 286-310, 1994. ISSN 0001-2998. Correlative Imaging: Part II. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0001299805800200>>.

PAWLAK, Zdzisław. **Rough sets.** International Journal of Computer & Information Sciences, Kluwer Academic Publishers-Plenum Publishers, v. 11, p. 341-356, 1982. ISSN 0091-7036. Disponível em: <<http://dx.doi.org/10.1007/BF01001956>>.

PENG, Yi; SHI, Yong. **Editorial: Multiple criteria decision making and operations research.** Annals of Operations Research, Springer US, v. 197, p. 1-4, 2012. ISSN 0254-5330. Disponível em: <<http://dx.doi.org/10.1007/s10479-012-1104-7>>.

PERNY, Patrice. **Multicriteria filtering methods based on concordance and non discordance principles.** Annals of Operations Research, p. 137-165, 1998.

POTESIL Vaclav; HUANG, Xiaolei; ZHOU, Sean Z. Automated tumour delineation using joint pet/ct information. In: **Proceedings...** [S.l.: s.n.], 2007.

ROY, Bernard. **Classement et choix en présence de points de vue multiples.** RAIRO - Operations Research - Recherche Opérationnelle, EDP Sciences, v. 2, n. V1, p. 57-75, 1968. Disponível em: <<http://eudml.org/doc/104443>>.

SCHIEPERS, Christiaan et al. Combining pet and ct: effect on volume measurements. In: NUCLEAR SCIENCE SYMPOSIUM CONFERENCE RECORD. **Proceedings...** [S.l.], 2002. v. 2, p. 1102-1104 vol.2.

SHI, Jianbo; MALIK, Jitendra. **Normalized Cuts and Image Segmentation.** IEEE Trans. Pattern Anal. Mach. Intell., IEEE Computer Society, Washington, DC, USA, v. 22, n. 8, p. 888-905, 2000. ISSN 0162-8828. Disponível em: <<http://dx.doi.org/10.1109/34.868688>>

STORN, Rainer; PRICE, Kenneth. Differential Evolution: A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces. J. of Global Optimization, Kluwer Academic Publishers, Hingham, MA, USA, v. 11, n. 4, p. 341-359, 1997. ISSN 0925-5001. Disponível em: <<http://dx.doi.org/10.1023/A:1008202821328>>.

THIE, Joseph A.; HUBNER, Karl F.; SMITH, Gary T. **Standardized Uptake Value and Influx.** Clinical Positron Imaging, v. 2, n. 2, p. 99 { 104, 1999. ISSN 1095-0397. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1095039799000114>>.

WALLENIUS, Jyrki. et al. **Multiple Criteria Decision Making, Multiattribute Utility Theory: Recent Accomplishments and What Lies Ahead.** Management Science, v. 54, n. 7, p. 1336-1349, 2008.

YEVSEYEVA, Iryna. **Solving Classification Problems with Multicriteria Decision Aiding Approaches.** [S.l.]: University of Jyväskylä, 2007.

YU, Huan. et al. **Coregistered FDG PET/CT-Based Textural Characterization of Head and Neck Cancer for Radiation Treatment Planning.** Medical Imaging, IEEE Transactions

on, v. 28, n. 3, p. 374-383, 2009. ISSN 0278-0062.

YU, Wei. **ELECTRE TRI: Aspects methodologiques et manuel d'utilisation**. Document du Lamsade, Université de Paris-Dauphine, 1992.

ZHANG, Harry. The Optimality of Naive Bayes. In: FLAIRS CONFERENCE. **Proceedings...** AAAI Press, 2004. Disponible en: <<http://www.cs.unb.ca/profs/hzhang/publications/FLAIRS04ZhangH.pdf>>.

ZHANG, Jilong et al. Computed diagnosis system for lung tumor detection based on pet/ct images. In: 3RD INTERNATIONAL CONFERENCE ON BIOMEDICAL ENGINEERING AND INFORMATICS (BMEI). **Proceedings...** [S.l.], 2010. v. 1, p. 166-170.

ZIMMERMANN, Hans J. **Fuzzy Set Theory-And Its Applications**. [S.l.]: Kluwer Academic Publishers. 2. ed, 1991.

ZOPOUNIDIS, Constantin.; DOUMPOS, Michael. **Multicriteria classification and sorting methods: A literature review**. European Journal of Operational Research, v. 138, n. 2, p. 229-246, 2002. ISSN 03772217. MCDA Methodologies for Classification and Sorting. Disponible en: <<http://www.sciencedirect.com/science/article/pii/S0377221701002430>>.