



**UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO
UNIVERSIDADE DO ESTADO DO RIO GRANDE DO NORTE
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA
COMPUTAÇÃO**



HUGO WENDELL MAIA

**UMA PROPOSTA PARA DETECÇÃO AUTOMÁTICA DE
CÂNCER DE PELE BASEANDO-SE EM
CARACTERÍSTICAS DE FORMA, COR E TEXTURA**

**MOSSORÓ - RN
2015**

HUGO WENDELL MAIA

**UMA PROPOSTA PARA DETECÇÃO AUTOMÁTICA DE
CÂNCER DE PELE BASEANDO-SE EM
CARACTERÍSTICAS DE FORMA, COR E TEXTURA**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação - associação ampla entre a Universidade do Estado do Rio Grande do Norte e a Universidade Federal Rural do Semi-Árido, para a obtenção do título de Mestre em Ciência da Computação.

Orientador: Profº Marcos Evandro Cintra, D.Sc.

**MOSSORÓ - RN
2015**

© Todos os direitos estão reservados a Universidade Federal Rural do Semi-Árido. O conteúdo desta obra é de inteira responsabilidade do(a) autor(a), sendo o mesmo, passível de sanções administrativas ou penais, caso sejam infringidas as leis que regulamentam a Propriedade Intelectual, respectivamente, Patentes: Lei nº 9.279/1996, e Direitos Autorais Lei nº 9.610/1998. O conteúdo desta obra tomar-se-á de domínio público após a data da defesa e homologação da sua respectiva ata. A mesma poderá servir de base literária para novas pesquisas, desde que a obra e seu(a) respectivo(a) autor(a) sejam devidamente citados e mencionados os seus créditos bibliográficos.

Dados Internacionais de Catalogação na Publicação (CIP)
BIBLIOTECA CENTRAL ORLANDO TEIXEIRA - CAMPUS MOSSORÓ
Setor de Informação e Referência

M217p Maia, Hugo Wendell.

Uma proposta para detecção automática de câncer de pele baseando-se em características de forma, cor e textura / Hugo Wendell Maia. - Mossoró, 2016.

84f: il.

Orientador: Dr. Marcos Evandro Cintra

Dissertação (MESTRADO EM CIÊNCIA DA COMPUTAÇÃO) - Universidade Federal Rural do Semi-Árido. Pró-Reitoria de Pesquisa e Pós-Graduação

1. Processamento digital de imagens. 2. Melanoma. 3. Sistema Fuzzy. I. Título

RN/UFERSA/BOT/009

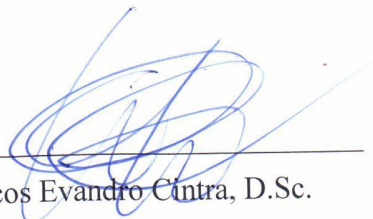
CDD 621.367

HUGO WENDELL MAIA

UMA PROPOSTA PARA DETECÇÃO AUTOMÁTICA DE CÂNCER DE PELE BASEANDO-SE
EM CARACTERÍSTICAS DE FORMA, COR E TEXTURA

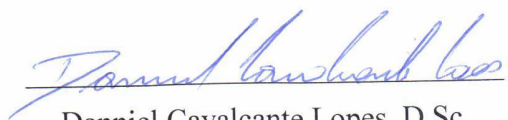
APROVADA EM: 10 / DEZEMBRO / 2015

BANCA EXAMINADORA:




Marcos Evandro Cintra, D.Sc.

Orientador



Daniel Cavalcante Lopes, D.Sc.

Examinador Interno (UFERSA)



Ana Trindade Winck, D.Sc.

Examinadora Externa (UFSM)

AGRADECIMENTOS

A Deus por ter me dado saúde e força para superar as dificuldades.

Aos meus pais Miguel Minervino Maia e Lenilda dos Santos Maia e ao meu irmão José Wellington Maia, pelo apoio e amor incondicional.

Ao meu orientador D.Sc. Marcos Evandro Cintra, por toda ajuda no desenvolvimento do trabalho.

RESUMO

O câncer de pele é o mais comum entre todos os cânceres. O melanoma é um tipo de câncer de pele maligno, responsável por muitas mortes em todo o mundo. O diagnóstico precoce desse tipo de câncer aumentam as chances de cura do paciente. Uma das formas de realizar esse diagnóstico é por meio da dermatoscopia. A dermatoscopia é uma técnica que consiste no reconhecimento de estruturas presentes na pele, não visíveis a olho nu. Com o auxílio de um dermatoscópio, equipamento que amplia a imagem, o médico faz o reconhecimento dessas estruturas e obtém o diagnóstico da lesão. Porém, apesar de analisar a imagem de forma ampliada, diversos fatores influenciam negativamente no diagnóstico. Na literatura, é possível encontrar diversas propostas para classificação automática de lesão de pele, algumas utilizando características de forma, cor e textura separadamente. Assim, visando auxiliar o uso da dermatoscopia por profissionais da área da saúde, este trabalho apresenta uma proposta para classificação automática de lesões de pele utilizando o algoritmo FuzzyDT, fundamentando-se em características de forma, cor e textura, analisadas pelos dermatologistas. A contribuição principal deste trabalho é a proposta da seleção de características com o uso do FuzzyDT, na qual obteve 100% de acurácia com o uso das seguintes características: Homogeneidade, Correlação, Energia, Rede de Pigmentos, Estrias, Branco, Vermelho, Marrom Escuro, Azulado e Preto.

Palavras-chave: Aprendizado de Máquina, Árvores de Decisão, Câncer de pele, Classificação, Dermatoscopia, FuzzyDT, Sistemas Fuzzy.

ABSTRACT

Skin cancer is the most common of all cancers. Melanoma is one type of malignant skin cancer, responsible for many deaths worldwide. Early diagnosis of this cancer increase the chances of curing the patient. One way to perform this diagnosis is by dermoscopy. Dermoscopy is a technique that consists of the recognition of structures present in the skin, not visible to the naked eye. With the aid of a dermatoscope, which is an equipment that enlarges the image, the doctor makes the recognition of these structures and obtains the diagnosis of the lesion. But despite analyze the image on a broader scale, many factors influence negatively in the diagnosis. In the literature, one can find several proposals for automatic skin lesion classification, using separately some features of shape, color and texture. Thus, aiming to support the use of dermoscopy by health professionals, this work presents a proposal for automatic classification of skin lesions using FuzzyDT algorithm, basing on characteristics of shape, color and texture, examined by dermatologists. The main contribution of this work is the proposal of feature selection using the FuzzyDT, which had 100% accuracy with the use of the following: homogeneity, correlation, Energy, Pigments Network, Streaks, White, Red, Dark Brown, Bluish and Black.

Key-words: Machine Learning, Decision Trees, Skin cancer, Classification, Dermoscopy, FuzzyDT, Fuzzy Systems.

LISTA DE FIGURAS

Figura 1 – Processo Geral da Proposta para Detecção Automática de Câncer de Pele.	15
Figura 2 – Exemplo de Ruídos (pelos) em Imagem de Lesão de Pele. (A) Antes do pré-processamento. (B) Depois do pré-processamento	18
Figura 3 – Segmentação em Imagem de Lesão de Pele. (A) Antes da segmentação. (B) Depois da segmentação.	20
Figura 4 – Processo de construção de uma matriz GLCM a partir da imagem.	25
Figura 5 – Árvore de Decisão, exemplo da financeira.	28
Figura 6 – Árvores de decisão clássica e fuzzy para o conjunto de dados Iris.	32
Figura 7 – Conjuntos fuzzy dos atributos de definição Comprimento da Pétala e Largura da Pétala.	32
Figura 8 – Exemplo de classificação segundo o $K-nn$	34
Figura 9 – Representação de um Neurônio Artificial.	37
Figura 10 – Exemplos de funções de ativação.	38
Figura 11 – RNA Multicamadas.	38
Figura 12 – Comparação entre os principais métodos.	41
Figura 13 – Imagens disponibilizadas no conjunto. (A) Original. (B) Máscara.	47
Figura 14 – Conversão de imagem RGB para tons de cinza.	48
Figura 15 – Segmentação da imagem em tons de cinza.	49
Figura 16 – Extração da matriz GLCM.	50
Figura 17 – Extração da matriz GLCM.	50
Figura 18 – Arquitetura geral da classificação em dois níveis.	52
Figura 19 – Vetor de Características.	53
Figura 20 – Vetor de características utilizando três características.	54
Figura 21 – Interação dos laços com o vetor de características.	54
Figura 22 – Geração do conjunto de dados I.	55
Figura 23 – Geração do conjunto de dados II.	56
Figura 24 – Comparação dos resultados obtidos pelos 21 algoritmos utilizando os três conjuntos de dados diferentes.	60
Figura 25 – Comparação dos resultados obtidos na classificação em três classes utilizando todas as características de forma e cor, com a utilização da seleção de características.	63
Figura 26 – Comparação entre resultados obtidos na classificação em três classes utilizando todas as características de texturas e utilizando a melhor combinação delas.	65

Figura 27 – Comparação entre resultados obtidos na classificação em três classes utilizando todas as características e utilizando a melhor combinação delas.	67
Figura 28 – Comparação dos resultados obtidos na primeira etapa da classificação, quando utilizadas todas as características e apenas as selecionadas. .	70
Figura 29 – Comparação dos resultados obtidos na segunda etapa da classificação, quando utilizadas todas as características e apenas as selecionadas. .	72
Figura 30 – Comparação dos resultados obtidos na classificação geral em duas etapas utilizando todas as características e apenas as características selecionadas.	74
Figura 31 – Comparação geral dos resultados.	75

LISTA DE TABELAS

Tabela 1 – Árvore de decisão: exemplo de uso.	29
Tabela 2 – Classificador Bayes: exemplo.	35
Tabela 3 – Resultados da classificação utilizando características de forma e cor.	58
Tabela 4 – Resultados da classificação utilizando características de textura.	59
Tabela 5 – Resultados da classificação utilizando características de forma, cor e textura.	60
Tabela 6 – Melhores combinações de características de forma e cor.	61
Tabela 7 – Resultados obtidos na classificação utilizando as características selev- cionadas de forma e cor descritas na Tabela 6.	62
Tabela 8 – Melhores combinações de características para classificação em três classes utilizando características de textura.	64
Tabela 9 – Resultados obtidos na classificação em três classes utilizando as melhores características de textura.	64
Tabela 10 – Melhores combinações de características para classificação em três classes utilizando características de forma, cor e textura.	66
Tabela 11 – Resultados obtidos na classificação em três classes utilizando as melhores características de forma, cor e textura.	66
Tabela 12 – Resultados obtidos na classificação em duas classes (nevo comum e nevo não comum) da primeira etapa da classificação, utilizando todas as características.	68
Tabela 13 – Resultados da classificação em duas classes (nevo atípico e melanoma), utilizando todas as características de forma, cor e textura.	68
Tabela 14 – Melhores combinações de características para a primeira etapa da classificação com seleção de características.	69
Tabela 15 – Resultado da classificação na primeira etapa utilizando as caracte- rísticas selecionadas.	70
Tabela 16 – Resultados obtidos na segunda etapa da classificação em duas classes, utilizando as características selecionadas.	71
Tabela 17 – Resultados obtidos na classificação em duas classes (nevo atípico e melanoma) utilizando as característica selecionadas.	72
Tabela 18 – Resultados obtidos na classificação geral feita em duas etapas.	73

LISTA DE ABREVIATURAS E SIGLAS

AM Aprendizado de Máquina

FDT FuzzyDT

GLCM *Gray-Level Co-Occurrence Matrix*

INCA Instituto Nacional de Câncer

IA Inteligência Artificial

K-nn K Vizinhos Mais Próximos

MLP *Multi Layer Peceptron*

NB Naive Bayes

PDI Processamento Digital de Imagens

RNA Redes Neurais Artificiais

RGB Red, Green e Blue

WEKA *Waikato Environment for Knowledge Analysis*

SUMÁRIO

1	INTRODUÇÃO	13
2	PROCESSAMENTO DIGITAL DE IMAGENS	17
2.1	Pré-processamento	17
2.1.0.1	Filtro de Mediana	17
2.1.0.2	Filtro de Difusão Anisotrópica	18
2.1.0.3	Filtragem Morfológica	19
2.2	Segmentação	19
2.2.0.4	Descontinuidade	19
2.2.0.5	Similaridade	20
2.3	Extração de Características de Forma e Cor	22
2.3.0.6	Regra ABCD	22
2.3.0.7	Análise de Padrões	23
2.3.0.8	Lista de Sete Pontos	23
2.4	Extração de Características de Textura	24
2.5	Conclusão	25
3	APRENDIZADO SUPERVISIONADO	26
3.1	Árvores de Decisão	27
3.2	FuzzyDT	30
3.3	K Vizinhos Mais Próximos (K -nn)	33
3.4	Naive Bayes	35
3.5	Redes Neurais Artificiais	36
3.6	Considerações Finais	39
4	TRABALHOS RELACIONADOS	40
4.1	Abordagens para Processamento de Imagens	40
4.2	Abordagens que Usam Características de Forma e Cor	42
4.3	Abordagens que Usam Características de Textura	43
4.4	Outros Trabalhos	44
4.5	Considerações Finais	45
5	PROPOSTA PARA CLASSIFICAÇÃO DE IMAGENS DE LESÕES DE PELE	46
5.1	Escolha de uma Base de Imagens	46
5.2	Extração da Imagem em Tons de Cinza	47
5.3	Segmentação	47

5.4	Extração das Características	48
5.5	Uso do Algoritmo FuzzyDT para a Classificação	49
5.5.1	Descrição dos Modelos de Classificação	49
5.5.2	Proposta de Clasificação em Duas Etapas	51
5.6	Considerações Finais	52
6	EXPERIMENTOS E ANÁLISE DOS RESULTADOS	53
6.1	Seleção de Características	53
6.2	Classificação em Duas Etapas	55
6.2.1	Experimentos de Classificação	56
6.3	Experimentos de Classificação Usando as Três Classes Originais (nevo comum, nevo atípico e melanoma)	57
6.3.1	Experimentos com Todos os Atributos de Forma e Cor.	58
6.3.2	Experimentos com Todos os Atributos de Textura.	58
6.3.3	Experimentos com Todos os Atributos de Forma, Cor e Textura.	59
6.3.4	Experimentos com Seleção de Atributos de Forma e Cor.	61
6.3.5	Experimentos com combinação de atributos de textura.	62
6.3.6	Experimentos com seleção de atributos de forma, cor e textura.	63
6.4	Classificação em Duas Etapas	65
6.4.1	Experimentos com classificação em duas classes (nevo comum e nevo não comum) com todos os atributos.	65
6.4.2	Experimentos com classificação em duas classes (nevo atípico e melanoma) com todos os atributos.	67
6.4.3	1ª etapa - experimentos com classificação em duas classes (nevo comum e nevo não comum) com seleção de atributos.	67
6.4.4	2ª etapa - experimentos com classificação em duas classes (nevo atípico e melanoma) com seleção de atributos.	71
6.5	Análise Geral dos Resultados	74
6.6	Considerações Finais	75
7	CONSIDERAÇÕES FINAIS	76
7.1	contribuições	76
7.2	Trabalhos Futuros	77
7.3	Publicações	77
	REFERÊNCIAS	78

1 INTRODUÇÃO

O câncer de pele é um dos tipos de câncer com maior crescimento nos últimos anos. De acordo com a Organização Mundial de Saúde (OMS)¹, em torno de 132 mil novos casos de melanoma (lesão de pele maligna) ocorrem globalmente a cada ano. No Brasil, segundo o INCA (Instituto Nacional de Câncer)², o câncer de pele é o de maior incidência, sendo responsável por cerca de 25% de todos os casos de câncer diagnosticados. As estatísticas em outros países são similares e bastante preocupantes. Nos EUA, por exemplo, ocorrem cerca de 10.000 mortes dos 40.000 a 50.000 casos diagnosticados por ano³. E em Portugal, segundo a Liga Portuguesa Contra o Cancro LPCC (2015), esse número chega a representar um terço de todos os cânceres diagnosticado no país.

Dentre os tipos de câncer de pele existente, o melanoma é o de menor incidência, porém com as maiores taxas de mortalidade. Segundo o INCA, de todos os cânceres de pele estimados no Brasil em 2016, apenas 4% são do tipo melanoma, sendo que desse total, em 70% dos casos os pacientes chegam a óbito.

Apesar da grande taxa de mortalidade ligada ao melanoma, o diagnóstico precoce da doença desempenha um papel essencial na diminuição desses números, já que a percentagem de sucesso na cura deste tipo de câncer é elevada, caso este seja detectado durante as etapas iniciais do seu desenvolvimento. É relatado na literatura (FRANGE; ARRUDA; DALDON, 2009) que a taxa de sobrevida do melanoma diagnosticado precocemente é de 90-97% em dez anos, e diminui para 10-15% quando diagnosticado em um estágio mais avançado.

Existem duas maneiras de realizar esse diagnóstico, através dos métodos invasivos ou dos não invasivos.

- **Forma invasiva:** executada por meio de uma biopsia, procedimento que consiste na análise laboratorial de um pedaço de tecido que é retirado da pele do paciente.
- **Forma não invasiva:** consiste da análise visual da lesão, no qual o profissional analisa algumas características que são comuns nesse tipo de lesão.

O primeiro método é feito por meio de uma biopsia, sendo assim custoso financeiramente e gerando incômodo ao paciente, pois necessita da retirada de um pedaço de pele para que seja feita uma análise laboratorial. Dado comprovado no trabalho realizado

¹ Disponível em: <<http://www.who.int/en/>>

² Disponível em: <<http://www2.inca.gov.br>>

³ Disponível em: <<http://www.melresproj.com/net/02001.html>>

por [Naser \(2011\)](#), que fez um levantamento dos gastos relacionados ao tratamento de câncer de pele no estado de São Paulo em 30 anos (1980 - 2009), onde constatou que do total de gastos destinados para o tratamento desse tipo de doença, apenas 4,2% são usados no tratamento de lesões em estado inicial, sendo todo o restante para os casos em estágios avançados.

O diagnóstico não invasivo pode ser feito de diferentes formas. Entre estas está a dermatoscopia, uma técnica introduzida por [Soyer et al. \(1987\)](#), que consiste no reconhecimento de estruturas morfológicas não visíveis a olho nu. Na prática médica, o aparelho mais utilizado para realizar a dermatoscopia é o dermatoscópio (instrumento que proporciona um aumento da imagem das lesões para uma melhor visualização).

Na dermatoscopia, o médico tem o auxílio do dermatoscópio para analisar as lesões baseando-se em algumas características. Apesar de analisar a lesão de forma ampliada e das características extraídas serem bem fundamentadas, esse diagnóstico é subjetivo, pois sofre interferência de alguns fatores, como:

- Cansaço e inexperiência do dermatologista;
- Iluminação irregular do ambiente;
- Lesões em estágios iniciais.
- Inexperiência do médico.

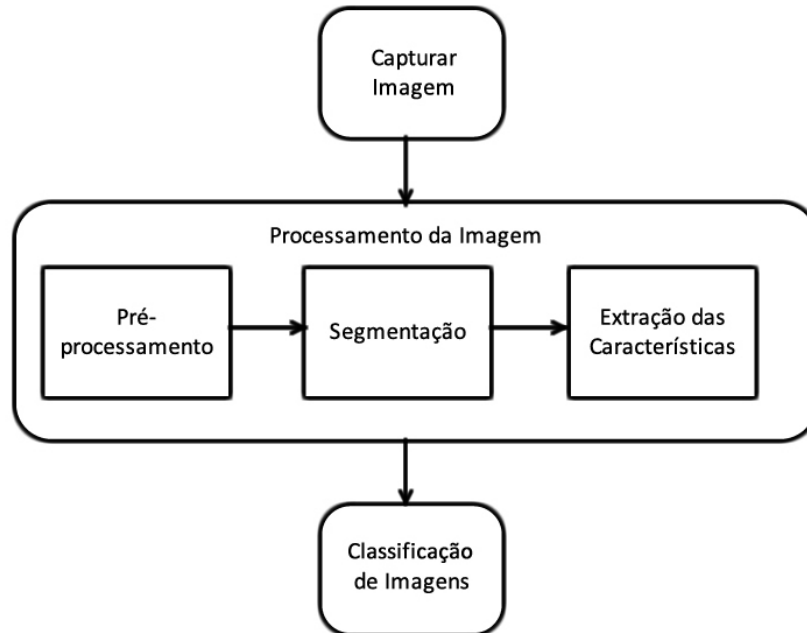
Visando diminuir a margem de erro dos diagnósticos não invasivos, e assim aumentar a sua precisão, pesquisadores de todo o mundo vêm desenvolvendo metodologias para automatizar a análise dessas lesões baseando-se nas mesmas características analisadas por profissionais da saúde, porém com o auxílio do computador.

Essa automatização baseia-se em programas de computadores que analisam imagens das lesões de pele. Para executar a análise automática é preciso seguir uma sequência de passos, como mostra a [Figura 1](#).

Inicialmente a imagem da lesão é capturada com o auxílio de um *dermatoscópio* (instrumento que proporciona o aumento das lesões cutâneas) ([FRANGE; ARRUDA; DALDON, 2009](#)). O segundo passo é o processamento da imagem, para extrair as características. Esse processo é subdividido em: pré-processamento, segmentação e extração de características, ambas definidas no [Capítulo 2](#). O terceiro passo é classificar a lesão, de acordo com as características retiradas na fase anterior. As técnicas utilizadas nessas fases são detalhadas no [Capítulo 3](#).

Apesar do grande número de trabalhos desenvolvidos para automatização da classificação de lesões de pele, os resultados obtidos em uma comparação entre métodos de aprendizado de máquina mais utilizados para classificar essas lesões apontam

Figura 1 – Processo Geral da Proposta para Detecção Automática de Câncer de Pele.



Fonte: Autoria Própria

que, apesar de uma taxa de acurácia em torno 89%, esses classificadores ainda precisam melhorar quanto ao reconhecimento das lesões malignas, visto que as taxas de especificidades obtidas não tem sido satisfatórias. Assim, visando auxiliar o uso da dermatoscopia por profissionais da área da saúde, o presente trabalho propôs o desenvolvimento de uma metodologia baseada na utilização do algoritmo FuzzyDT, um algoritmo para classificação que combina o poder das árvores de decisão com a capacidade de representação do conhecimento humano da lógica fuzzy, para automatizar a classificação de lesões de pele, fundamentando-se em características de forma, cor e textura.

A principal contribuição desse trabalho é a extração de novas características, juntamente com a seleção de características, o que possibilitou o algoritmo FuzzyDT obter melhores resultados. Outra contribuição desse trabalho é a listagem de quais características geram melhores resultados em outros 20 algoritmos diferentes, possibilitando o uso dos algoritmos extraindo suas melhores classificações.

Este trabalho encontra-se dividido da seguinte forma: no Capítulo 2 é exposta a fundamentação teórica relacionada ao processamento digital de imagens. O Capítulo 3 traz definições de técnicas de aprendizado de máquina supervisionado estudadas

neste trabalho. No Capítulo 4 são citados alguns trabalhos relacionados. No Capítulo 5, é detalhado o desenvolvimento deste trabalho para classificação de imagens de lesões de pele. No Capítulo 6 são detalhados todos os experimentos realizados, bem como a análise dos resultados obtidos. Por fim, o Capítulo 7 traz as considerações finais.

2 PROCESSAMENTO DIGITAL DE IMAGENS

A manipulação de uma imagem por um computador, no qual tem-se como entrada e saída uma imagem, é chamada de Processamento Digital de Imagens. O objetivo de se usar esse processamento é melhorar o aspecto visual das imagens possibilitando uma melhor interpretação, facilitando a extração de informações das mesmas (GONZALEZ; WOODS, 2010). O processamento é composto por:

- Pré-processamento
- Segmentação
- Extração de características

2.1 PRÉ-PROCESSAMENTO


Imagens de lesões de pele são variadas, com diferentes formas e intensidades de ruído, como pelos, sombra, linhas da pele e diferentes tipos de iluminação, podendo gerar distorções na definição da lesão e conseqüentemente, na classificação, tornando assim, o pré-processamento, uma etapa importante no processamento de imagens. Esses ruídos podem ser amenizados ou até mesmo removidos com a aplicação de filtros de suavização (GONZALEZ; WOODS, 2010). Alguns filtros têm sido bastante utilizados nas propostas encontradas na literatura, como o de mediana e o difusão anisotrópica (PERONA; MALIK, 1990). A aplicação desses filtros pode ser feita individualmente ou combinados, tentando extrair o melhor de cada método.

A Figura2(a) mostra um exemplo de imagem com ruído (pêlos), e a Figura2(b) mostra a mesma imagem após a remoção dos ruídos. No processamento dessa imagem foi usado o sistema DullRazor, proposto por Lee et al. (1997), para executar o pré-processamento de imagens. A seguir são descritos alguns dos filtros encontrados em trabalhos relacionados a classificação de lesões de pele.

2.1.0.1 Filtro de Mediana

O filtro de mediana é um filtro não linear, bastante usado para eliminar ruídos em imagens. Ele reduz satisfatoriamente os ruídos, preservando os traços originais das

Figura 2 – Exemplo de Ruídos (pelos) em Imagem de Lesão de Pele. (A) Antes do pré-processamento. (B) Depois do pré-processamento



Fonte: (SUPOT, 2014)

imagens. Ao contrário dos filtros lineares, como o filtro de média, que borra a imagem, ele suaviza a mesma sem perder suas bordas e detalhes finos (GONZALEZ; WOODS, 2010). Por essa razão, o filtro de mediana é frequentemente aplicado para suavização de imagens de lesões de pele, uma vez que a preservação da borda original da imagem é importante para o processo seguinte, o de segmentação da lesão ((CELEBI; ASLANDOGAN; BERGSTRESSER, 2005); (CELEBI et al., 2008); (CHIEM; AL-JUMAILY; KHUSHABA, 2007); (LAU; AL-JUMAILY, 2009)).

A caracterização desse filtro se dá pelo uso de máscaras, que consiste na troca do valor do pixel pelo valor da mediana de sua vizinhança. A vizinhança é estabelecida pelo tamanho da máscara que foi definida (CHIEM; AL-JUMAILY; KHUSHABA, 2007). Na literatura, é possível encontrar trabalhos voltados para definição das máscaras, como em Lau e Al-Jumaily (2009) e Celebi et al. (2008).

2.1.0.2 Filtro de Difusão Anisotrópica

Usado para suavização de imagens, o filtro de difusão anisotrópica também é utilizado em imagens de lesões de pele para eliminação de ruídos. É um filtro não linear, e sua aplicação se dá por meio de iterações, que são definidas de acordo com a quantidade de ruídos presentes na imagem; Seu uso resulta numa suavização seletiva. Contudo, quando aplicado em excesso, esse filtro pode eliminar as bordas da lesão.

O filtro de difusão anisotrópica para suavização de lesões de pele foi usado por Pires

e Barcelos (2007), que utilizaram o método que propõe uma complementação no algoritmo inicialmente apresentado por Perona e Malik (1990). O algoritmo além de permitir a eliminação dos ruídos presentes na imagem, realça a borda, que é uma característica importante para a definição do contorno da lesão. Esse algoritmo também tem por objetivo suavizar imagens muito ruidosas, sem eliminar a borda.

2.1.0.3 Filtragem Morfológica

A filtragem morfológica (FACON, 1996) é caracterizada por resultar de uma operação não-linear entre a imagem e um elemento estruturante. Segundo Gonzalez e Woods (2010), essa filtragem é bastante usada para suavização de imagens e remoção de ruídos, nos quais são usados os operadores morfológicos de abertura e fechamento.

2.2 SEGMENTAÇÃO

A segmentação é a etapa que subdivide uma imagem em regiões ou objetos que a compõe. Para que um método computacional de auxílio a diagnóstico de lesões de pele seja eficiente, o contorno extraído deve preservar as características de irregularidade da fronteira da lesão (MA et al., 2010). A aplicação do método de segmentação ocorre até que o objeto de interesse, neste caso a lesão de pele, seja isolado do restante da imagem.

Alguns ruídos, como pelos, sardas e manchas, influenciam no resultado de sua aplicação, tornando-a uma tarefa complexa. Dessa forma, as técnicas de pré-processamento de imagens podem ser utilizadas anteriormente, objetivando melhorar o desempenho na etapa de segmentação.

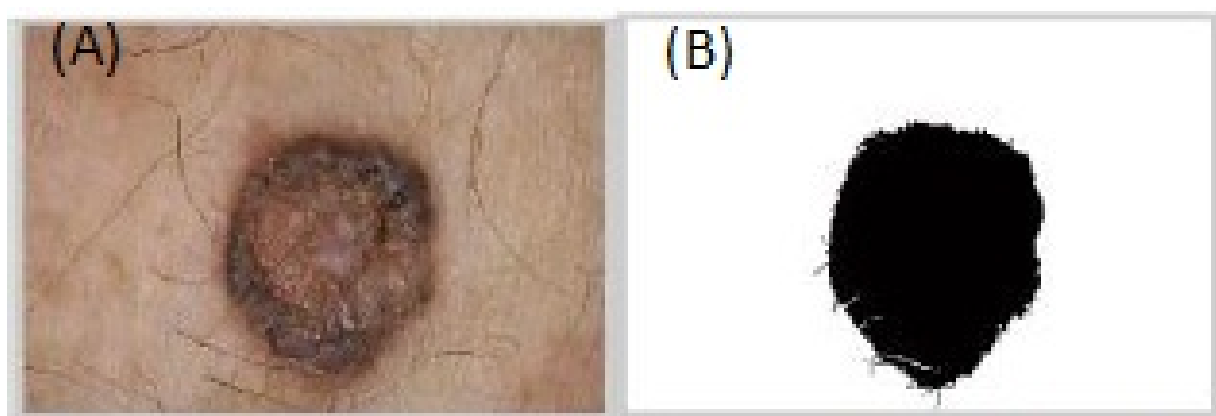
Geralmente, a segmentação é baseada nas propriedades de descontinuidade e similaridade, explicadas a seguir. A Figura 3(b) mostra um exemplo de segmentação em da Figura 3(a).

2.2.0.4 Descontinuidade

Técnicas baseadas em descontinuidades podem localizar objetos de três tipos (NEVES; PELAES, 2001):

- pontos;
- linhas;
- bordas.

Figura 3 – Segmentação em Imagem de Lesão de Pele. (A) Antes da segmentação. (B) Depois da segmentação.



A descontinuidade se baseia nas mudanças abruptas de intensidades dos pixels, interligando-os quando estão próximos, como os detectores de borda. Em geral, os detectores de borda, como Prewitt, Sobel e Roberts, podem apresentar problemas como: determinar bordas em locais que não existe fronteira; não determinar bordas quando realmente existe fronteira; detectar bordas duplas ((SONKA; HLAVAC; BOYLE, 1998) (GONZALEZ; WOODS, 2010) (CANNY, 1986)).

2.2.0.5 Similaridade

As principais abordagens de similaridade são baseadas em limiares (*thresholding*) e crescimento de regiões (*region growing*) (GONZALEZ; WOODS, 2010). Em imagens de lesões de pele, a segmentação usando critério de similaridade baseia-se em características como cor e textura. A seguir são detalhados os métodos de limiarização e crescimento de região, que adotam essa metodologia.

Limiarização

As metodologias de segmentação baseadas em limiares tentam separar as regiões de interesse do fundo da imagem, usando valores como classificadores de uma característica particular ((GONZALEZ; WOODS, 2010); (YUKSEL; BORLU, 2009); (CUDEK; GRZYMALA-BUSSE; HIPPE, 2010); (BEUREN et al., 2012)). Esta técnica tem como resultado uma imagem binária, na qual a cor preta pode representar a lesão e a branca a pele. A sua aplicação consiste na escolha de limiar ou

múltiplos limiares, para fazer a separação dos níveis de cinza da imagem, que são representados em um histograma.

No método de limiarização um passo muito importante é a definição do limiar, no qual é definido o limite de separação entre os pixels, assim, devido a sua importância, existem trabalhos destinados apenas na definição do limiar, como é o caso de [Otsu \(1978\)](#), que se baseia no histograma normalizado para definir o valor do limiar ótimo que separa os pixels de uma determinada imagem em duas classes homogêneas com variância mínima entre as classes. Observando que a borda definida pelo método de Otsu tende a ser menor do que o tamanho correto da lesão na maioria das imagens, bem como pelo fato de apresentar uma borda bastante irregular, [Yuksel e Borlu \(2009\)](#) apresentaram uma abordagem utilizando técnicas de lógica fuzzy do tipo-2 ([MENDEL; JOHN, 2002](#)) que determina um limiar automático para segmentar imagens. Esta técnica apresenta bom desempenho em lidar com valores incertos para definir se um determinado nível de cinza pertence à lesão ou pertence à pele.

Outro método para definição do limiar é o de entropia de Renyi ([SAHOO; WILKINS; YEAGER, 1997](#)), considerando que o processo de limiarização é mais eficiente, uma vez que evita modificar a geometria e forma da lesão.

Crescimento de Regiões

A outra técnica baseada em similaridade, cuja utilização é voltada para segmentação de lesões de pele, é a por crescimento de região ([CELEBI; ASLANDOGAN; BERGSTRESSER, 2005](#)). Na tentativa de unir o maior número possível de pixels em regiões homogêneas, têm sido propostos métodos baseados em crescimento de regiões (([LEE et al., 1997](#)) ([CELEBI et al., 2008](#))).

Uma abordagem frequentemente usada é de dividir a imagem de entrada em conjuntos de regiões disjuntas, esta técnica é um processo que agrupa *pixels* vizinhos semelhantes ou sub-regiões em regiões maiores (homogêneas) de acordo com um critério de crescimento.

Esse processo inicia com um conjunto de pontos, no qual cada ponto que possui propriedades semelhantes em uma determinada região, tais como, nível de cinza, textura ou cor, são agrupados, causando o crescimento da mesma. Depois de obtida a região de crescimento pode ser aplicado uma operação de fusão de região (*merging*) para obter a imagem final segmentada. O *merging* permite que as regiões sejam fundidas, ou seja, é definida a mesma intensidade para todos os *pixels* que possuam intensidades semelhantes de acordo com o parâmetro de crescimento.

2.3 EXTRAÇÃO DE CARACTERÍSTICAS DE FORMA E COR

Para ser realizada a classificação das lesões de pele é necessário algumas informações referentes às mesmas, e a partir daí classificá-las. Alguns métodos utilizados são: regra ABCD, análise de padrão e lista de sete pontos. Tais técnicas são descritas a seguir.

2.3.0.6 Regra ABCD

Para o diagnóstico das lesões de pele, algumas características como assimetria, irregularidade da borda, variação da cor interna e o diâmetro são analisadas. Essas características são conhecidas como ABCD das lesões de pele (ou regra ABCD). Segue o detalhamento das mesmas:

- *Assimetria (A)* Simétrica: lesões que geralmente são não cancerosas e/ou não malignas, sendo mais arredondadas. *Assimétrica*: lesões que possuem grandes probabilidades de serem cancerosas malignas.
- *Borda (B)* *Lisa*: lesões não malignas possuem bordas lisas e suaves. *Rugosa ou cortada*: frequentemente lesões malignas possuem bordas irregulares.
- *Cor (C)* *Regular*: lesões com cor interna homogênea que, na maioria das vezes, não são malignas. *Irregular*: geralmente os melanomas possuem coloração interna com grande variação das intensidades marrom e preta, podendo ter regiões em branco.
- *Diâmetro (D)* *Menor que 6mm*: lesões não malignas geralmente possuem diâmetro inferior a 6 mm e não variam de tamanho. *Maior que 6mm*: frequentemente os melanomas são maiores do que 6 mm de diâmetro, crescem e mudam de forma rapidamente.

De acordo com [Pires e Barcelos \(2007\)](#) vem sendo avaliada a adição da característica *evolução* à essa regra, que consiste na avaliação na modificação das características da lesão ao longo do tempo. O que está motivando essa adição, é o fato das lesões estarem evoluindo bem rápido em pouco tempo.

Segundo [Smith \(1996\)](#) os profissionais da área médica enfatizam estas características quando analisam as imagens de lesões, principalmente as de contorno. Esta regra permite ao dermatologista fazer uma análise prévia da lesão, definindo os procedimentos a serem seguidos até que exames mais detalhados sejam feitos.

Indo mais além, [Muller et al. \(2009\)](#) propuseram uma avaliação do aprendizado da regra ABCD por pacientes atendidos em centros dermatológicos na região Sul do Brasil.

Sua pesquisa foi realizada em 80 pacientes, de ambos os sexos, com faixa etária acima de 12 anos. Concluíram que essa regra pode ser usada para capacitar pacientes acima de 17 anos e identificar alterações sugestivas nas lesões, favorecendo, assim, a detecção precoce do câncer.

2.3.0.7 Análise de Padrões

O método de análise de padrões foi descrito inicialmente por [Pehamberger, Steiner e Wolff \(1987\)](#). Essa metodologia definiu padrões dermatoscópicos característicos das lesões pigmentadas da pele e, em 2000, foi atualizada pelo Consensus Net Meeting ([REZZE; Sá; NEVES, 2006](#)).

As lesões de pele são caracterizadas por padrões, tais como: globular, homogêneo e reticular, que podem ser identificados nas imagens de exame de pele obtidas pela análise de padrão, para definir se a lesão é benigna ou maligna. O tamanho, forma e distribuição dos padrões tornam-se desiguais no interior da lesão maligna, contrariamente à lesão benigna onde os padrões são uniformes em toda a região. Essa análise foi aplicada por [Mendoza, Serrano e Acha \(2009\)](#) para identificar o tipo de padrão, para que então possa ser utilizada para a identificação em melanoma ou nevo. Extraíram características baseando-se no histograma de intensidade, estatística diferencial, *fourier*, *matrix run-length* e matrizes de co-ocorrência, como também utilizaram análise estatística para definir o padrão da lesão.

2.3.0.8 Lista de Sete Pontos

Este método é utilizado para análise computacional de lesões de pele em imagens dermatoscópicas em [Leo et al. \(2009\)](#) e [Leo et al. \(2010\)](#). São sete critérios estabelecidos e divididos em maiores (2 pontos) e menores (1 ponto), se a soma total for menor do que três, a lesão é considerada benigna, caso seja igual ou maior que três, a lesão é considerada maligna. A seguir são listados os sete critérios ordinalmente ([PROCIANOY, 2009](#)):

Os critérios maiores representam:

1. Presença de pigmentação atípica;
2. Véu branco azulado;
3. Padrão de vascularização não-típica.

Os critérios menores são compostos por:

4. Estrias irregulares;

5. Pigmentação irregular;
6. Pontos ou glóbulos irregulares;
7. Estruturas de regressão.

2.4 EXTRAÇÃO DE CARACTERÍSTICAS DE TEXTURA

A GLCM (Matriz de Co-Ocorrência de Nível de Cinza) é uma técnica utilizada dentro da área de análise de texturas, que foi desenvolvida na década de 70 pelo pesquisador [Haralick \(1979\)](#). Baseando-se em estatísticas, são analisadas as co-corrências existentes entre pares de pixels, levando em consideração também a distância entre os pixels em questão, bem como a direção de encontro dos mesmos.


Uma GLCM é uma matriz sempre quadrada que mantém informações das intensidades relativas dos pixels em uma dada imagem. Ela calcula as probabilidades de co-ocorrências entre dois níveis de cinza i e j , dada uma certa distância s e uma orientação Q (tetha), que pode assumir os valores de 0° , 45° , 90° , 135° , 180° , 225° , 270° e 315° ([HARALICK, 1979](#)). Existe uma matriz de co-ocorrência para cada relacionamento espacial possível (combinações da distância s e da orientação Q). Todas as informações sobre a textura de uma imagem estarão contidas nessa matriz.

Um exemplo de uma matriz GLCM obtida a partir dos pixels de uma imagem pode ser visto na Figura 4. Observe que o relacionamento estabelecido é (1,1), ou seja, um pixel adjacente horizontalmente a uma distância unitária. O elemento na linha 1 e coluna 1 da matriz GLCM tem o valor 1, o que indica que existe apenas uma única situação na imagem onde um pixel de nível de intensidade 1 é adjacente horizontalmente a um outro pixel de nível de intensidade 1. O elemento na linha 1 e coluna 2 da matriz GLCM tem o valor 2, o que indica que existem duas ocorrências na imagem onde um pixel de nível de intensidade 1 é adjacente horizontalmente a um pixel de nível de intensidade 2. Esse processo é repetido até que a matriz GLCM esteja completa.

Variando o vetor usado para se obter a matriz de co-ocorrência, permitiu-se encontrar diferentes características de textura. Dentre as pesquisadas, as características mais utilizadas em trabalhos dessa natureza são: contraste, homogeneidade, energia e correlação, de acordo com as Equações de 2.1 a 2.4 respectivamente.

$$\text{Contraste} = \sum_{i,j=0}^{n-1} P_{i,j}(i - j)^2 \quad (2.1)$$

Figura 4 – Processo de construção de uma matriz GLCM a partir da imagem.



Fonte: mathworks ¹

$$Homogeneidade = \sum_{i,j=0}^{n-1} \frac{P_{i,j}}{1 + (i - j)^2} \tag{2.2}$$

$$Energia = \sum_{i,j=0}^{n-1} (P_{i,j})^2 \tag{2.3}$$

$$Correlação = \sum_{i,j=0}^{n-1} P_{i,j} \frac{(i - \mu)(j - \mu)}{\sigma^2} \tag{2.4}$$

onde P(i,j) é a posição na matriz GLCM, sendo i o número da linha e o j a coluna.

2.5 CONCLUSÃO

Neste capítulo, foram apresentados alguns conceitos sobre as fases de processamento digital de imagens necessárias em trabalhos de classificação de lesões de pele, sendo essas divididas em: Pré-processamento - responsável por remover os ruídos presentes nas imagens, segmentação - fase em que a lesão é separada do restante da imagem e extração das características - responsável por extrair as características que serão usadas como entrada para a classificação.

No próximo, são apresentados os conceitos básicos sobre os algoritmos de aprendizado de máquina supervisionado, ou de classificação, usados no desenvolvimento deste trabalho.

3 APRENDIZADO SUPERVISIONADO

Alguns problemas são facilmente resolvidos por humanos, como reconhecer pessoas pela fisionomia ou fala. Para isso, é adquirido um conhecimento prévio, que possibilite a diferenciação entre os padrões existentes. Um bom médico consegue, baseado em um conjunto de sintomas (características) e de exames clínicos, estabelecer um diagnóstico em relação a um paciente. Para isso, ele utiliza o conhecimento adquirido durante sua formação, bem como a experiência do dia-a-dia.

Para que um computador consiga reconhecer padrões, como por exemplo, diferenciar entre pessoas usando imagens dos seu rostos, é necessário a utilização de alguma técnica computacional que auxilie a decisão. Técnicas de Inteligência Artificial (IA), em especial, de Aprendizado de Máquina (AM), vem sendo utilizadas na resolução desses problemas. Inteligência Artificial, segundo [Winston \(1992\)](#), é o estudo das computações que tornam possível perceber, raciocinar e agir. Aprendizado de máquina é uma subárea de IA. Segundo [Mitchell \(1997\)](#) é a capacidade de melhorar o desempenho na realização de alguma tarefa por meio da experiência.

Algoritmos de AM têm sido utilizados em diversas tarefas, como diagnósticos médicos, reconhecimento de padrões, visão computacional, dentre outros, que podem ser organizadas de acordo com diferentes critérios. Um deles diz respeito ao paradigma de aprendizado a ser adotado para lidar com a tarefa. De acordo com esse critério, as tarefas de aprendizado de máquina podem ser divididas em ([CARVALHO, 2011](#)):

- **Aprendizado Supervisionado:** tem como meta encontrar uma função a partir dos dados de treinamento que possa ser utilizado para prever um rótulo ou um valor que caracterize um novo exemplo. Os algoritmos ou métodos de AM utilizados nessa tarefa induzem modelos preditivos. Fazem parte do paradigma supervisionado.
- **Aprendizado não Supervisionado:** tem como meta explorar ou descrever um conjunto de dados. Os algoritmos de AM utilizados nessa tarefa não fazem uso do atributo de saída. Por isso seguem o paradigma de aprendizado não supervisionado.

Nas seções a seguir são definidos alguns métodos de aprendizado de máquina supervisionado utilizados na classificação de lesões de pele, sendo eles: árvores de decisão, FuzzyDT, K vizinhos mais próximos, naive bayes e redes neurais.

3.1 ÁRVORES DE DECISÃO

As árvores de decisão usam a estratégia de dividir para conquistar para resolver problemas de decisão. Os problemas complexos são divididos em problemas de menor complexidade, que por sua vez também são divididos. Os subproblemas são resolvidos e a combinação de suas soluções produzem a solução final. Algoritmos como ID3 (QUINLAN, 1979), CART (BREIMAN et al., 1984) e C4.5 (QUINLAN, 1993), usam essa ideia em suas fundamentações. A Figura 5 representa uma árvore de decisão, na qual cada nó interno (Renda e Bens) contém um teste condicional baseado em valores dos atributos, e os nós folha (Baixo, Médio, e Alto) representam uma classe específica.

Uma árvore de decisão pode prever qualquer tipo de entrada, pois todo o espaço de instâncias estão presentes na mesma. Para classificar instâncias, são analisados um conjunto de condições presentes no percurso da raiz até uma das folhas da árvore, ou seja, em cada nó interno contém um condição, que ao ser avaliada, decide qual o próximo nó que aquela instância deve seguir, assim ao fim do percurso, a instância estará na folha que representa a classe que a mesma faz parte (RUSSELL; NORVIG, 2004).

A Figura 5 demonstra um exemplo do uso de uma árvore de decisão para a análise de crédito. Baseando-se nas informações de renda e bens do cliente, a árvore informa o risco ao qual a financeira será submetida caso libere o financiamento para aquele cliente. Nesse exemplo foi levado em consideração três tipos de riscos diferentes: alto, médio e baixo.

A seguir são detalhadas as etapas mais gerais de criação de árvores de decisão.


Indução

A fase em que a árvore é construída é chamada de indução. Nessa fase é definido qual atributo será usado em cada nó. Existem diferentes critérios para selecionar os atributos, sendo essa a principal diferença entre os algoritmos existentes.

O principal conceito nessa proposta é o de entropia (H). A entropia consiste em medir a aleatoriedade (dificuldade de prever) de uma variável. Suponha uma variável aleatória discreta A , cujo o domínio é a_1, a_2, \dots, a_n e a probabilidade de se observar cada uma é $p(a_1), p(a_2), \dots, p(a_n)$. O cálculo da entropia de A ($H(A)$) é mostrada na Equação 3.1.

$$H(H(A)) = \sum_{i=1}^n -P(a_i) \log_2 P(a_i) \quad (3.1)$$

Figura 5 – Árvore de Decisão, exemplo da financeira.



Fonte: autoria própria

Para verificar a Equação 3.1, no caso do lançamento de uma moeda imparcial, obtêm-se:

$$H\left(\frac{1}{2}, \frac{1}{2}\right) = -\frac{1}{2} \log_2 \frac{1}{2} - \frac{1}{2} \log_2 \frac{1}{2} = 1 \quad (3.2)$$

No caso de uma moeda adulterada para dar 99% de cara, o valor da entropia é:

$$H\left(\frac{1}{100}, \frac{99}{100}\right) = -\frac{1}{100} \log_2 \frac{1}{100} - \frac{99}{100} \log_2 \frac{99}{100} = 0,08 \quad (3.3)$$

Logo, como é possível perceber, quanto mais equilibrada for a divisão entre os ramos, mais próximo de 1 (um) será a entropia, como é o caso da moeda honesta, e quanto mais esse valor se aproximar de 0 (zero), mais desbalanceada será a árvore, como é o caso da moeda desonesta.

A medida de ganho de informação (IG) verifica a redução na entropia nas partições obtidas de acordo com os valores do atributo. O ganho de informação é dado pela diferença entre a entropia do conjunto de exemplos e a soma ponderada das entropias das partições, como mostrado na Equação 3.4. A construção da árvore de decisão é guiada pelo objetivo de reduzir a entropia, isto é, reduzir a aleatoriedade da variável alvo. Fórmula do cálculo do ganho de informação (CARVALHO, 2011).

$$IG(A, p, q) = I(p, q) - E(A, p, q) \quad (3.4)$$

Suponha o conjunto de treinamento apresentado na Tabela 1. O problema de decisão é decidir quando alguém joga ou não algum esporte dadas as condições do tempo. O problema é definido por quatro atributos de entrada: tempo, temperatura, umidade e vento.

Tabela 1 – Árvore de decisão: exemplo de uso.

Tempo	Temperatura	Umidade	Vento	Joga
Chuvoso	71	91	Sim	não
Ensolarado	69	70	não	Sim
Ensolarado	80	90	Sim	não
Nublado	83	86	não	Sim
Chuvoso	70	96	não	Sim
Chuvoso	65	70	Sim	não
Nublado	64	65	Sim	Sim
Nublado	72	90	Sim	Sim
Ensolarado	75	70	Sim	Sim
Chuvoso	68	80	não	Sim
Nublado	81	75	não	Sim
Ensolarado	85	85	não	não
Ensolarado	72	95	não	não
Chuvoso	75	80	não	não

Fonte: Autoria Própria

De acordo com esses dados, baseando-se no cálculo de entropia e ganho de informação, qual atributo seria melhor para ficar na raiz da árvore ?

Cálculo da entropia (H) geral:

$$P(joga = sim) = 9/14$$

$$P(joga = nao) = 5/14$$

$$H(joga) = -9/14 * \log_2(9/14) - 5/14 * \log_2(5/14) = 0,940$$

Cálculo da entropia (H) de cada partição:

$$P(joga = sim | Tempo = Ensolarado) = 2/5$$

$$P(joga = nao | Tempo = Ensolarado) = 3/5$$

$$H(joga | Tempo = Ensolarado) = -2/5 * \log_2(2/5) - 3/5 * \log_2(3/5) = 0,971$$

Similarmente para as outras partições do atributo tempo:

$$H(joga | Tempo = Nublado) = 0,0$$

$$H(joga | Tempo = Chuvoso) = 0,971$$

A entropia ponderada para o atributo tempo é:

$$H(Tempo) = 5/14 * 0,971 + 4/14 * 0,0 + 5/14 * 0,971 = 0,693$$

Logo, o ganho de informação obtido pelo atributo tempo é:

$$IG(\text{Tempo}) = H(\text{joga}) - H(\text{Tempo}) = 0,940 - 0,693 = 0,247$$

Sabendo que os demais atributos obtiveram um ganho de informação menor que o do tempo, esse atributo é escolhido para ficar na raiz da árvore.

Poda

Em domínios com ruídos, um processo muito importante em relação as árvores de decisão é o de poda. Esse processo consiste na troca dos nós profundos por folhas. Dados ruidosos levantam dois problemas. O primeiro é que as árvores induzidas por esses dados classificam novos objetos de uma maneira não confiável. E o segundo é que a árvore induzida tende a ser grande, assim dificultando o entendimento da solução. Logo, a poda ajuda a minimizar esses problemas.

Métodos de poda podem ser divididos em dois grupos principais. Primeiro, métodos que param a construção da árvore quando algum conceito é satisfeito, chamados de pré-poda. Essa técnica conta com regras de parada que previnem a construção de ramos que não parecem melhorar a precisão preditiva da árvore, tendo como vantagem a minimização do tempo na construção. O segundo grupo é composto por métodos que constroem a árvore completa e depois executam a poda, chamados de pós-poda. Esse caso é baseado em algumas medidas, entre elas o *erro estatístico* e o *erro de backed-up*. O *erro estatístico* é o número de classificações incorretas considerando que todos os exemplos que chegam nesse nó são classificados usando a classe majoritária da distribuição de classes desse nó. O *erro de backed-up* é a soma das classificações incorretas de todas as subárvores do nó corrente (CARVALHO, 2011).

Na literatura é possível encontrar alguns trabalhos que realizam a classificação de lesões de pele utilizando árvores de decisão, como em Celebi et al. (2008), que usam uma árvore de decisão para classificar os pixels da imagem em duas classes: véu e não véu, e a partir daí classificar a lesão.

3.2 FUZZYDT

O FuzzyDT¹, algoritmo proposto por Cintra e Camargo (2010), usa as mesmas medidas do algoritmo clássico C4.5 (QUINLAN, 1993) (entropia e ganho de informação) para decidir a importância das características. Contudo, para o FuzzyDT, características contínuas são definidas em termos de conjuntos fuzzy antes da indução na árvore. Deste modo, o processo de induzir uma árvore usando FuzzyDT pega um conjunto de

¹ Disponível em <<https://dl.dropboxusercontent.com/u/16102646/FuzzyDT.zip>>

características discretizadas, uma vez que as características contínuas são definidas em termos de conjuntos fuzzy e o conjunto de treinamento é fuzzificado antes que ocorra a indução da árvore de decisão. O Algoritmo a seguir descreve FuzzyDT.

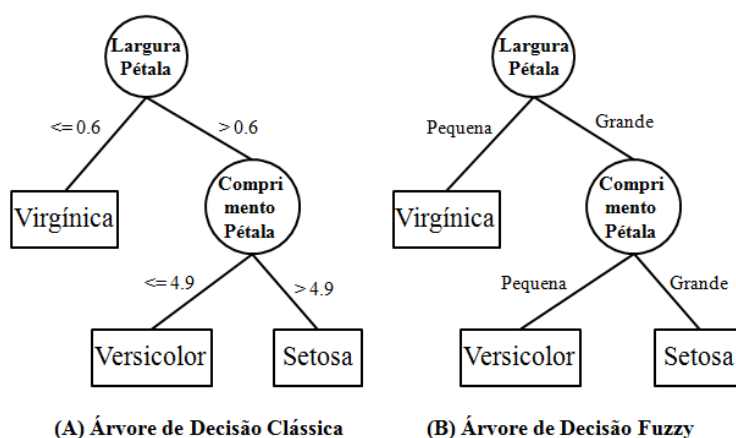
O Algoritmo FuzzyDT:

1. Definir a base dados fuzzy, isto é, a granulação fuzzy para os domínios das características contínuas;
2. Substituir os atributos contínuos para o conjunto de treinamento usando os rótulos linguísticos dos conjuntos fuzzy com os valores de entrada de maior compatibilidade;
3. Calcular a entropia e o ganho de informação de cada característica para dividir o conjunto de treinamento e define os nós de teste da árvore até que todas as características sejam usadas ou todos os exemplos de treinamento sejam classificados;
4. Aplicar um processamento pós-poda, similarmente ao C4.5, usando 25% de limites de confiança como padrão.

Como a fuzzificação dos dados de treinamento é feita antes da indução da árvore, o terceiro passo do algoritmo FuzzyDT corresponde ao mesmo passo do algoritmo clássico da árvore de decisão C4.5.


Como estabelecido anteriormente, uma questão especial que diz respeito às árvores de decisão é o fato de que elas podem ser vistas como um conjunto de regras disjuntas nas quais apenas uma regra é acionada para classificar um novo exemplo. Contudo, embora uma árvore de decisão fuzzy possa ser vista como um conjunto de regras, diferentemente do modelo clássico, muitas dessas regras são acionadas simultaneamente, cada uma com um grau de compatibilidade com um exemplo de entrada, na intenção de classificar esse novo exemplo. A Figura 6 ilustra essa característica especial das árvores de decisão difusas com um exemplo hipotético baseado no conjunto de dados Iris disponibilizado por Lichman (2013). Esse exemplo usa apenas dois atributos para classificar as novas entradas em três tipos de plantas iris: Setosa, Versicolor e Virginica. A árvore de decisão do lado esquerdo da Figura 6 é a clássica, enquanto a sua versão fuzzy similar é a da direita. No intuito de ser capaz de interpretar as variáveis linguísticas fuzzy e os termos linguísticos da árvore de decisão fuzzy, a Figura 7 apresenta os conjuntos fuzzy dos atributos de definição Comprimento da Pétala e Largura da Pétala usados na Figura 6. Para simplificação, apenas dois conjuntos de formas triangulares (pequeno e grande) eventualmente distribuídos nas partições são usados. A Figura 7 mostra as funções associativas para o Comprimento da Pétala e a Largura da Pétala (CINTRA, 2012).

Figura 6 – Árvores de decisão clássica e fuzzy para o conjunto de dados Iris.



Fonte: (CINTRA, 2012)

Figura 7 – Conjuntos fuzzy dos atributos de definição Comprimento da Pétala e Largura da Pétala.



Fonte: (CINTRA, 2012)

O processo de dedução da árvore de decisão clássica é bastante direto: se Largura da Pétala é ≤ 0.6 , o exemplo pertence à classe Virgínica, caso contrário, o atributo Comprimento da Pétala é testado; se ele é ≤ 4.9 , o exemplo é classificado como Versicolor, caso contrário ele é classificado como Setosa. Deste modo, considerando um novo exemplo de entrada para ser classificado tendo Comprimento da Pétala = 4.9 e Largura da Pétala = 0.6, ambos os valores no limite da discretização da árvore de decisão clássica, apenas a primeira regra é acionada:

SE Largura da Pétala é ≤ 0.6 ENTÃO Classe é Virgínica

Contudo, para a árvore de decisão fuzzy, os graus associativos do exemplo de entrada, mostrados na Figura 5.3 (Comprimento da Pétala Pequeno = 0.66; Comprimento da Pétala Grande = 0.34; Largura da Pétala Pequena = 0.79; Largura da Pétala Grande = 0.21) são usados para calcular o grau de compatibilidade do exemplo de entrada com cada regra. Para esse exemplo particular, usando o mínimo como *t-norm*, os graus de compatibilidade das regras fuzzy são (em parênteses):

1. SE Largura da Pétala é Pequeno ENTÃO Classe é Virginica (0.79)
2. SE Largura da Pétala é Grande E Comprimento da Pétala é Pequeno ENTÃO Classe é Versicolor (0.21)
3. SE Largura da Pétala é Grande E Comprimento da Pétala é Grande ENTÃO Classe é Setosa (0.21)

Para esse exemplo, usando o método clássico de raciocínio fuzzy (melhor regra), a classe da primeira regra é usada para classificar o exemplo como Virginica, a qual é a mesma classe definida pela árvore de decisão clássica. Agora, assumindo que a Largura da Pétala do exemplo de entrada seja 0.61, enquanto o Comprimento da Pétala continua o mesmo. Note que a diferença na Largura da Pétala entre esse exemplo e o último exemplo não é significativa (0.01). Desse modo, a classe de tais exemplos similares deveria ser a mesma. Não obstante, a árvore de decisão clássica classifica esse novo exemplo como pertencente à classe Versicolor. A árvore de decisão fuzzy, em outra via, uma vez que ela usa os graus de compatibilidade dos valores de entrada com os conjuntos difusos definindo os testes da árvore, ainda classifica esse novo exemplo na mesma classe, Virginica. Note que a mesma situação pode ocorrer para o Comprimento da Pétala, bem como com qualquer atributo contínuo com uma discretização quebradiça. Essa robustez das árvores de decisão difusas é altamente desejável.

Nesta seção foram apresentados os principais conceitos sobre Conjuntos Fuzzy, Lógica Fuzzy e Sistemas Fuzzy, em especial os Sistemas Fuzzy de Classificação, alvo de estudo deste trabalho. Todos os conceitos detalhados nesse capítulo podem ser encontrados na íntegra em (CINTRA, 2007; CINTRA; CAMARGO, 2010; CINTRA, 2012).


3.3 K VIZINHOS MAIS PRÓXIMOS (K-NN)

Baseando-se na hipótese de que dados similares tendem a estar concentrados em uma mesma região do espaço de entrada, os métodos baseados em distância levam

em consideração a proximidade entre os dados na realização das predições. Um dos algoritmos baseados em distância mais utilizados é o K -nn (K nearest neighbors) (CARVALHO, 2011).

Sucintamente, essa técnica compara o exemplo de entrada com os exemplos do conjunto de treino e determina os k exemplos de treino mais próximos do exemplo de entrada. Com o conjunto $Tr = a_1, a_2, \dots, a_n$. Para classificar um novo elemento x , calcula-se as distâncias de x a todos os elementos de Tr e determina-se os k mais próximos de x . Dentre os k mais próximos verifica-se qual a classe que aparece com mais frequência, sendo o elemento x classificado dentro da classe mais frequente. Fazendo uma analogia a Figura 8, o conjunto de entrada seria os quadrados azuis e os triângulos vermelhos, e o elemento que se deseja classificar seria o círculo verde. Logo, se $k = 1$, o círculo verde pertence a classe dos quadrados, porém se $k = 3$, o círculo passa a pertencer a classe dos triângulos.

Figura 8 – Exemplo de classificação segundo o K -nn.



Fonte: autoria própria

Em alguns casos o valor de k interfere diretamente na escolha da classe, como visto na figura acima, na qual quando o $k = 1$, o exemplo foi classificado em uma classe, e quando o $k = 3$, a classificação apontou outra classe. A escolha do melhor valor de k depende do exemplo, assim o valor de k geralmente é determinado experimentalmente. Para tal, começa-se escolhendo uma gama de valor de k , e para cada um desses valores é estimada uma taxa de erro do classificador, sendo escolhido o valor que retornar a menor taxa de erro (RUSSELL; NORVIG, 2004).

É possível encontrar alguns trabalhos que utilizam o K -nn para classificar lesões de pele, como em Ruiz et al. (2011) que usou o K -nn para classificar lesões de pele e

mostrou que em comparação com outros métodos mais complexos, ele, apesar de simples, obteve resultados similares.

3.4 NAIVE BAYES

Outro algoritmo de aprendizado de máquina usado para classificar lesões de pele é o Naive Bayes. Os classificadores de Bayes são classificadores estatísticos que classificam um objeto numa determinada classe baseando-se na probabilidade desse objeto pertencer a essa classe. Esse método utiliza dois conceitos de probabilidade para classificar. O primeiro é a probabilidade a priori $P(c)$, que consiste na observação da frequência com que o evento c ocorre, antes de verificar a evidência. E o segundo é a probabilidade a posteriori, que consiste na observação da frequência com que o evento c ocorre, após verificar a evidência.

Em outras palavras, a observação x é classificada numa classe c para a qual a probabilidade a posteriori $P(c | x)$ for a mais alta possível. Essa probabilidade é conhecida por probabilidade a posteriori da classe c porque é calculada depois de ser observado o vetor x . As probabilidades a posteriori são calculadas usando o teorema de Bayes, conforme definido pela Equação 3.5 (MITCHELL, 1997):

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

Tabela 2 – Classificador Bayes: exemplo.

Idade	Renda	Aluno	Crédito	Classe
<= 30	alta	não	normal	não
<= 30	alta	não	excelente	não
31...40	alta	não	normal	sim
> 40	média	não	normal	sim
> 40	baixa	sim	normal	sim
> 40	baixa	sim	excelente	não
31...40	baixa	sim	excelente	sim
<= 30	média	não	normal	nao
<= 30	baixa	sim	normal	sim
> 40	média	sim	normal	sim
<= 30	média	sim	excelente	sim
31...40	média	não	excelente	sim
31...40	alta	sim	normal	sim
> 40	média	não	excelente	não

Fonte: Autoria Própria

Na Tabela 2, contém dados para o problema sobre a decisão quanto a compra ou não de um computador, levando em consideração quatro fatores: idade, renda, crédito e se o comprador é aluno. Segue a resolução do problema utilizando as probabilidades.

$P(C_i)$:

$$P(\text{compraComputador} = \text{"sim"}) = 9/14 = 0.643$$

$$P(\text{compraComputador} = \text{"nao"}) = 5/14 = 0.357$$

Calculo de $P(X|C_i)$ para cada classe:

$$P(\text{Idade} = \text{"<= 30"} \mid \text{compraComputador} = \text{"sim"}) = 2/9 = 0.222$$

$$P(\text{Idade} = \text{"<= 30"} \mid \text{compraComputador} = \text{"nao"}) = 3/5 = 0.6$$

$$P(\text{Renda} = \text{"media"} \mid \text{compraComputador} = \text{"sim"}) = 4/9 = 0.444$$

$$P(\text{Renda} = \text{"media"} \mid \text{compraComputador} = \text{"nao"}) = 2/5 = 0.4$$

$$P(\text{Aluno} = \text{"sim"} \mid \text{compraComputador} = \text{"sim"}) = 6/9 = 0.667$$

$$P(\text{Aluno} = \text{"sim"} \mid \text{compraComputer} = \text{"nao"}) = 1/5 = 0.2$$

$$P(\text{Credito} = \text{"normal"} \mid \text{compraComputador} = \text{"sim"}) = 6/9 = 0.667$$

$$P(\text{Credito} = \text{"normal"} \mid \text{compraComputador} = \text{"nao"}) = 2/5 = 0.4$$

Para o exemplo $X = (\text{Idade} = \text{"<= 30"}, \text{Renda} = \text{"media"}, \text{Aluno} = \text{"sim"}, \text{Crédito} = \text{"normal"})$, obtem-se:

$P(X | C_i)$:

$$P(X \mid \text{compraComputador} = \text{"sim"}) = 0.222 * 0.444 * 0.667 * 0.667 = 0.044$$

$$P(X \mid \text{compraComputador} = \text{"nao"}) = 0.6 * 0.4 * 0.2 * 0.4 = 0.019$$

$P(X | C_i) * P(C_i)$:

$$P(X \mid \text{compraComputador} = \text{"sim"}) * P(\text{compraComputador} = \text{"sim"}) = 0.028$$

$$P(X \mid \text{compraComputador} = \text{"nao"}) * P(\text{compraComputador} = \text{"nao"}) = 0.007$$

Logo, o exemplo X pertence à classe ("compraComputador = sim")

Usando-se o Algoritmo Naive Bayes, todos os atributos da base de dados são considerados independentes entre si. Portanto, embora seja admitida a não existência de dependências condicionais entre os atributos, o naive, ainda assim, apresenta resultados confiáveis e fiéis a base de dados (VIANA, 2014). O Naive Bayes se destaca entre os métodos de aprendizado existentes, como um dos mais simples e, computacionalmente eficientes, sendo robusto contra ruídos nos dados e atributos irrelevantes (MITCHELL, 1997).


3.5 REDES NEURAIIS ARTIFICIAIS

As Redes Neurais Artificiais (RNA) são algoritmos computacionais, cuja meta é interpretar e resolver problemas computacionais baseando seu funcionamento no do

cérebro humano (HAYKIN, 1998). Elas são capazes de adquirir conhecimento utilizando um conjunto de neurônios artificiais, que são unidades de processamento interligadas entre si. Essa estrutura fornece às RNAs uma capacidade de processamento paralelo e distribuído, conferindo adaptabilidade, capacidade de aprendizado, generalização, tolerância a falhas, possibilidade de armazenamento distribuído e facilidade de prototipagem (RUSSELL; NORVIG, 2004).

Essas unidades de processamento desempenham um papel muito simples, como mostra a Figura 9. Cada terminal de entrada do neurônio recebe um valor. Os valores recebidos são ponderados e combinados por uma função matemática $F(a)$. A saída da função é a resposta do neurônio.

Figura 9 – Representação de um Neurônio Artificial.



Fonte: autoria própria

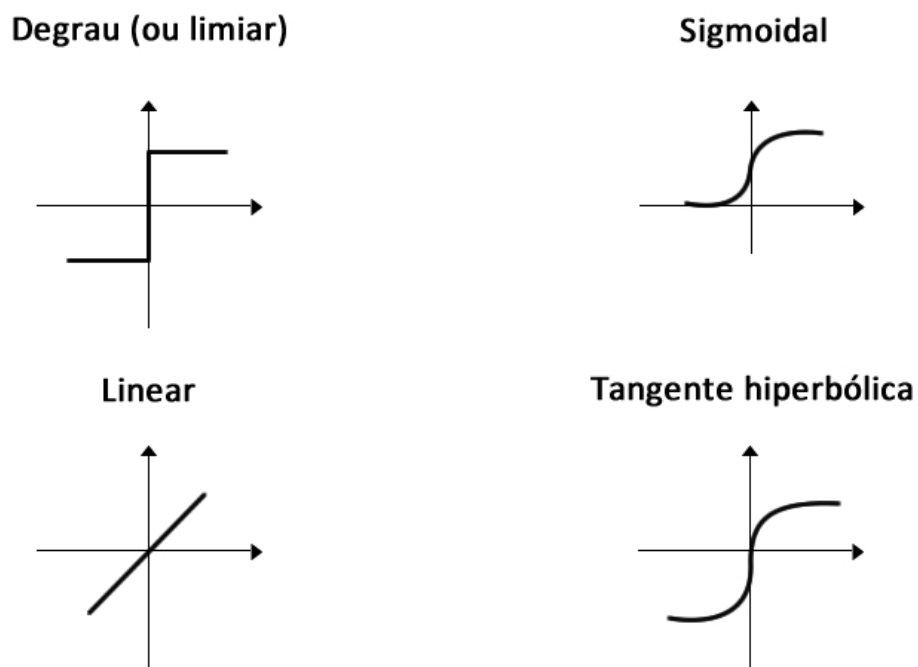
Várias funções têm sido propostas na literatura. A Figura 10 mostra o formato de quatro dessas funções, as funções linear, limiar, sigmoideal e Tangente Hiperbólica.

Em uma RNA, os neurônios podem estar dispostos em uma ou mais camadas. Quando mais de uma camada é utilizada, um neurônio pode receber em uma de suas entradas valores de saída de outros neurônios que estão em camadas anteriores como também enviar seus resultados para entradas de outros neurônios (CARVALHO, 2011). A Figura 11 mostra um exemplo de RNA com três camadas. Nesse exemplo, são passados inicialmente quatro valores de entrada e geram valores de saída que servirão como entradas para os neurônios das camadas intermediárias (ou ocultas), que por sua vez, geram dois valores de saída.

A utilização de métodos de RNA incluem vantagens como:


- Facilidade de otimização, resultando numa modelagem rentável e flexível mesmo com um grande conjunto de dados;
- Acurácia para inferência preditiva, com potencial para apoiar a tomada de decisões clínicas;

Figura 10 – Exemplos de funções de ativação.



Fonte: autoria própria

Figura 11 – RNA Multicamadas.



Fonte: autoria própria

As RNA já foram utilizadas na área de classificação de lesões de pele como [Hintz-Madsen et al. \(2001\)](#), que fizeram um *framework* para detecção de melanoma maligno

utilizando uma rede neural artificial probabilística e [Rubegni et al. \(2002\)](#) que utilizaram redes neurais para diferenciação entre melanoma de outras lesões benignas e obtiveram uma acurácia máxima de 93%.

3.6 CONSIDERAÇÕES FINAIS

Neste capítulo, foram apresentados os principais conceitos sobre árvores de decisão, K-nn, Naive Bayes e redes neurais. Também foram mostrados exemplos de utilização desses algoritmos para facilitar o entendimento dos mesmos.

No próximo capítulo, serão apresentadas algumas pesquisas relacionadas com o presente trabalho, detalhando algumas características das mesmas.

4 TRABALHOS RELACIONADOS

Na literatura, é possível encontrar vários trabalhos relacionados à detecção automática de lesões de pele, desde estudos que tratam apenas do aprimoramento do processamento de imagens, trabalhos completos que utilizam características de forma e cor, fazendo referência à Regra ABCD, trabalhos que utilizam somente características de textura, até trabalhos que comparam a qualidade dos sistemas existentes.

A seguir são descritas proposta desenvolvidas com o objetivo de melhorar a classificação de lesões de pele. Sendo estes trabalhos divididos da seguinte forma: relacionados ao processamento de imagens, trabalhos utilizando características de forma e cor; trabalhos utilizando características de textura; trabalhos utilizando características de forma, cor e textura; E por fim, pesquisas que avaliaram alguns sistemas já desenvolvidos.

4.1 ABORDAGENS PARA PROCESSAMENTO DE IMAGENS

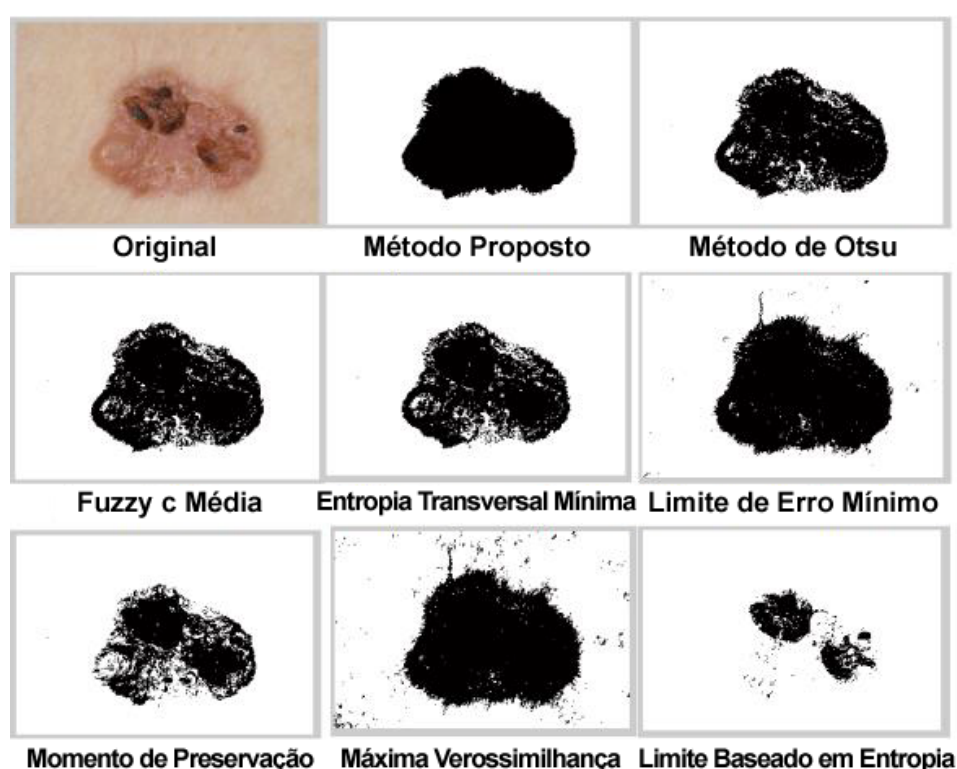
A primeira fase de um sistema de diagnóstico automático de lesões de pele é o processamento das imagens. Em geral, essa fase é composta por três subfases ([CAVALCANTI; SCHARCANSKI, 2013](#)):

1. Pré-processamento, na qual a imagem de entrada é processada de modo que os seus ruídos sejam eliminados a fim de facilitar o passo seguinte;
2. Segmentação, para a delimitação da fronteira da lesão, no qual a lesão é separada do resto da imagem;
3. Extração de características, no qual são extraídas das imagens as informações relevantes que servirão como entrada para a fase seguinte, de classificação.

No trabalho de [Masood e Al-Jumaily \(2014\)](#) é proposto um método para processar imagens, que unifica as vantagens de alguns algoritmos já existentes, tentando além de uma boa segmentação, reduzir a complexidade computacional. De acordo com os testes feitos pelos autores, comparando os resultados obtidos com os resultados de algoritmos conhecidos, o método atingiu uma melhora significativa na segmentação, além de um melhor desempenho. Na verificação experimental, foi utilizado um grande conjunto de imagens de lesões de pele, com quase todos os tipos de ruídos esperados,

que podem afetar gravemente os resultados da segmentação. A avaliação de precisão foi feita por meio da comparação de resultados obtidos pelo método proposto com os métodos ditos pelo autor como do estado da arte, como mostra a Figura 12, que exibe a imagem original e as imagens segmentadas utilizando diferentes técnicas. Os resultados mostram que a abordagem proposta executa bem, quando comparado com os demais, e pode formar uma base de processamento de imagens para ser usada em sistemas automáticos de diagnóstico para o câncer de pele.

Figura 12 – Comparação entre os principais métodos.



Fonte: Adaptado de (MASOOD; AL-JUMAILY, 2014)

No trabalho de Beuren et al. (2012), foi proposta uma abordagem para segmentação de lesões de pele, que filtra a imagem da lesão usando operadores morfológicos em cor, que em seguida é segmentada por binarização. Nenhum conhecimento a priori sobre o tipo de melanoma é empregado. Os experimentos realizados a partir de duas bases de imagens de melanoma benigno e maligno mostraram as potencialidades da abordagem no que diz respeito à segmentação.

4.2 ABORDAGENS QUE USAM CARACTERÍSTICAS DE FORMA E COR

Além dos trabalhos voltados para o processamento das imagens, também é possível encontrar trabalhos que propõem soluções para todas as fases, como em [Celebi \(2014\)](#) que apresentou uma abordagem de aprendizagem de máquina para a quantificação automática de cores clinicamente significativas em imagens dermatoscópicas. Dada uma imagem feita por um dermoscópico, primeiro é reduzido o número de cores da imagem a um pequeno conjunto dessas, usando o algoritmo de agrupamento K-means, que incorpora um termo espacial. O número de cores ideal para a imagem é estimado. Então o algoritmo de regressão simbólica é treinado, usando as estimativas apresentadas, que são calculados em um conjunto de 617 imagens. Finalmente, a equação matemática dada pelo algoritmo de regressão é usada para duas classes de classificação (benignos e malignos). A abordagem proposta produz uma sensibilidade de 62% e uma especificidade de 76% em um conjunto de teste independente de 297 imagens.

Outro trabalho que também propõe a análise completa das imagens é o de [Abuzagheh, Barkana e Faezipour \(2014\)](#), que desenvolveu um sistema de análise de imagem em tempo real para ajudar na prevenção de melanoma maligno e detecção precoce. É apresentada uma técnica de reconhecimento de imagem, na qual o usuário é capaz de capturar imagens de diferentes tipos de lesões de pele. O sistema proposto por eles, analisa e processa as imagens e alerta o usuário, em tempo real, para procurar ajuda médica, se for o caso. Este trabalho introduziu medidas convenientes para automatizar o processo de prevenção e detecção de melanoma. Os resultados experimentais em um banco de dados de imagens dermatoscópicas confirma a eficiência do sistema.

A proposta de [Oliveira et al. \(2012\)](#), mostrou o passo a passo da extração de características. Eles retiraram informações sobre formato da borda. Foi utilizado o SVM (*support vector machines*) para caracterizar as lesões em simétricas ou assimétricas, e em lisa ou rugosa. Após a caracterização, as informações são passadas para o dermatologista afim de que o mesmo diagnostique a lesão. A precisão máxima obtida utilizando essa metodologia foi de 73%.

O trabalho de [Ganzeli et al. \(2011\)](#) também propõe um sistema para diagnóstico de lesões de pele. Na fase do processamento das imagens, foi utilizado o detector de borda de [Canny \(1986\)](#). Na fase de classificador, eles propuseram uma árvore de decisão adaptativa, que se diferencia das árvores tradicionais pelo fato de ser modificada, baseando-se em correções feitas pelos usuários. Segundo os autores, a árvore inicial obteve 65% de acertos, tendo esse número aumentado para 90%, quando realizada a adaptação.

Fazendo referência às características da regra ABCD, que retratam as formas e as cores presentes nas lesões, (RUIZ et al., 2011) desenvolveram uma metodologia para detecção automática de lesões de pele. Eles extraíram 24 características referentes a regra ABCD. Com esse vetor de características, eles fizeram teste e encontraram duas combinações de características. A primeira combinação foi escolhida usando a técnica *Sequential Floating Forward Selection* (SFFS), que parte da melhor característica individual, depois escolhe a segunda melhor e assim por diante. A segunda técnica utilizada foi a *Sequential Floating Backward Selection* (SFBS), que consiste no inverso da anterior, ou seja, partindo de todas as características vai sendo retirada a pior, depois a segunda pior, e assim por diante. Em comparação, a técnica que obteve o melhor resultado foi a SFFS, com as seguintes características: fator de forma, simetria, extensão e as médias de tom, saturação e leveza do modelo de cor HSL. Usando a técnica de amostragem *10-folds cross validation*, os autores fizeram testes em três algoritmos diferentes: KNN, classificador Bayesiano, MLP e uma combinação dos três. Os resultados obtidos foram: 73,47%, 80,61%, 86,73% e 87,76%, para os algoritmos citados acima, respectivamente.

4.3 ABORDAGENS QUE USAM CARACTERÍSTICAS DE TEXTURA

Além dos trabalhos utilizando características de forma e cor, existem trabalhos que utilizam apenas características de textura, como o proposto por (MAURYA et al., 2014). A metodologia usada nessa pesquisa consistiu das seguintes fases: pré-processamento, extração de características, seleção de características, classificação e por último avaliação. Na primeira fase a imagem foi inicialmente redimensionada para um padrão de 512 x 512 pixels, e depois convertida para níveis de cinza. Feito isso, foram retiradas 23 características das lesões tendo por base a matriz de co-ocorrência (GLCM). Com o objetivo de selecionar só as melhores, foram realizados testes com as 23, verificando que os resultados eram melhores quando usadas apenas 12 delas. Para a classificação, foi utilizada a rede neural Multi Layer Perceptrom (MPL), sendo obtido uma acurácia de 92,0%. Foram utilizadas 102 imagens, sendo 51 retiradas de Dermquest¹ e 51 de Dermnet², e a técnica de amostragem utilizada foi a *Holdout* com 75% para treino e 25% para teste.

Utilizando características de textura, (RANJAN, 2012) desenvolveu um sistema para automatizar a detecção de lesões de pele. Baseados nas matrizes GLCM e WDM ele extraiu as características necessárias para classificação dessas lesões. Com relação à primeira, foram retiradas cinco características: contraste, homogeneidade, energia, média

¹ Disponível em <<http://www.dermquest.com>>

² Disponível em <<http://www.dermnet.com>>

e variância. E relacionadas à WDM foram extraídas cinco características, relacionadas aos níveis diferentes. Após a extração dessas características, foram feitos testes visando a combinação que retornasse a melhor precisão, sendo escolhida as características de homogeneidade e média, que chegaram a 83,30% de precisão. O algoritmo utilizado na obtenção desse resultado foi o K vizinhos mais próximos, com $k = 7$. Na tentativa de melhorar esse resultado, o autor testou as características com uma RNA, e descobriram que a característica de homogeneidade era suficiente, obtendo uma precisão de 88,60%.

4.4 OUTROS TRABALHOS

Diante do número de propostas existentes, Chadwick et al. (2014) resolveram analisar alguns já desenvolvidos. Foram testados 5 aplicativos relevantes, utilizando 15 imagens de lesões e comparando os graus de risco dos aplicativos para o diagnóstico conhecido das lesões. Dois dos aplicativos não identificaram nenhum dos melanomas. Os 3 restantes obtiveram 80% de sensibilidade para identificação de risco de melanoma. Já para a especificidade, os 5 aplicativos variaram de 20% a 100%. Cada aplicativo, desde a sua própria classificação e recomendação, incluiu um aviso recomendando avaliação do dermatologista regularmente, independentemente do resultado da análise. Os resultados indicam que a análise da lesão automática ainda não está pronta para ser utilizada como uma ferramenta de triagem. E o autor chama a atenção em relação a falta de restrições e regulamentos para estas aplicações.

A revista Exame Informática³, em janeiro de 2015, apresenta uma matéria intitulada como “as novas tecnologias”. Em seu texto falou sobre o avanço da tecnologia em apoio à área médica, citando várias metodologias que foram desenvolvidas visando esse apoio. Entre as tecnologias citadas pela revista, encontra-se o “*melanoma detection*”, um aplicativo criado no instituto Fraunhofer Portugal, para detecção de melanoma. Este aplicativo visa o auto-monitoramento que coleta, processa e armazena informações de lesões de pele por meio de sua classificação automática. A classificação feita por esse sistema baseia-se na regra do ABCD, que consiste em 4 características visuais relevantes para a detecção de câncer de pele, e para os quais foram desenvolvidos algoritmos para medir e quantifica-los.

³ Disponível em <<http://exameinformatica.sapo.pt/videos/reporterei/2013-04-13-app-criada-em-portugal-para-detetar-o-cancro-na-pele>>

4.5 CONSIDERAÇÕES FINAIS

Neste capítulo são apresentados alguns trabalhos relacionados com a presente pesquisa, sendo estes divididos em: processamento de imagens, utilizando características de forma e cor, utilizando características de textura e outros trabalhos, incluindo algumas propostas do estado da arte.

No próximo capítulo, é apresentada a proposta para o classificador automático de lesões de pele.

5 PROPOSTA PARA CLASSIFICAÇÃO DE IMAGENS DE LESÕES DE PELE

O presente trabalho apresenta uma proposta para classificação de lesões de pele de forma automática, baseando-se em características selecionadas de forma, cor e textura. Os passos principais desta proposta são:

1. Escolha de uma base de imagens;
2. Extração da imagem em tons de cinza;
3. Segmentação;
4. Extração das características;
5. Uso do algoritmo FuzzyDT para a classificação;

A seguir, são detalhados esses passos.

5.1 ESCOLHA DE UMA BASE DE IMAGENS


Para o desenvolvimento deste trabalho foi adotada a base de imagens PH¹ (MENDONÇA et al., 2013). Alguns fatores influenciaram na escolha desse conjunto de imagens, entre eles:

- Bastante utilizada na literatura
- Feita por profissionais da área da saúde
- Composta por 200 imagens de boa qualidade
- Os exemplos contemplam todas as classes, com 80 nevo comum, 80 nevo atípico e 40 melanoma.

Foram utilizadas todas as imagens, sendo essas disponíveis no formato RGB (*Red*, *Green* e *Blue*), com resolução padrão de 767 x 576 pixels. Além das 200 imagens originais, a base também disponibiliza as máscaras das mesmas, como mostra a Figura 13. A Figura 13(a) mostra uma imagem original e a Figura 13(b) sua respectiva máscara.

¹ Disponível em <<http://www.fc.up.pt/addi/ph2%20database.html>>

Figura 13 – Imagens disponibilizadas no conjunto. (A) Original. (B) Máscara.



Fonte: Autoria Própria


5.2 EXTRAÇÃO DA IMAGEM EM TONS DE CINZA

Para a extração da imagem em tons de cinza, o presente trabalho utilizou a seguinte sequência de passos. Inicialmente, a imagem original foi separada em suas primitivas (*Red*, *Green* e *Blue*). Cada primitiva é multiplicada por um valor, sendo 0.30, 0.59 e 0.11, que são valores relacionados aos termos R, G e B, respectivamente. Após a multiplicação, foram somados os três valores e o resultado foi o valor do *pixel* da imagem em tons de cinza. Para este processamento, foi utilizado o *software* MATLAB (VIEIRA, 2013). A Figura 14 ilustra essa extração.

5.3 SEGMENTAÇÃO

A segmentação da lesão, foi feita da seguinte forma: Em paralelo, foram percorridas, *pixels* a *pixel*, as imagens (original e máscara), e baseado no valor (0 ou 1) encontrado na máscara, uma terceira imagem foi gerada, sendo esta a imagem segmentada. A Figura 15 retrata esse procedimento.

Figura 14 – Conversão de imagem RGB para tons de cinza.




Fonte: Autoria Própria

5.4 EXTRAÇÃO DAS CARACTERÍSTICAS

O segundo passo da proposta para classificação automática de lesões de pele foi a extração de características. De posse da imagem segmentada e em tons de cinza, iniciou-se a extração de matriz de co-ocorrência (GLCM). Visando a obtenção de informações mais precisas, foram extraídas 8 matrizes GLCM de cada imagem, cada uma retratando uma direção diferente, sendo elas: 0° , 45° , 90° , 135° , 180° , 225° , 270° e 315° . Após extraídas, foi feita a soma, posição a posição, das 8 matrizes, resultando apenas em uma matriz para cada imagem, como ilustrado na Figura 16.

Da matriz resultante, foram retiradas as quatro informações que caracterizam a lesão, contraste, homogeneidade, correlação e energia, baseando-se em textura. A Figura 17 mostra essa fase do processo. Em todo o processo de extração de características de textura, foi utilizado o *software* MATLAB (VIEIRA, 2013).

Figura 15 – Segmentação da imagem em tons de cinza.



Fonte: Autoria Própria

5.5 USO DO ALGORITMO FUZZYDT PARA A CLASSIFICAÇÃO

Após a execução de alguns experimentos foi proposto o uso do Algoritmo FuzzyDT fundamentando-se em características selecionadas de forma, cor e textura.

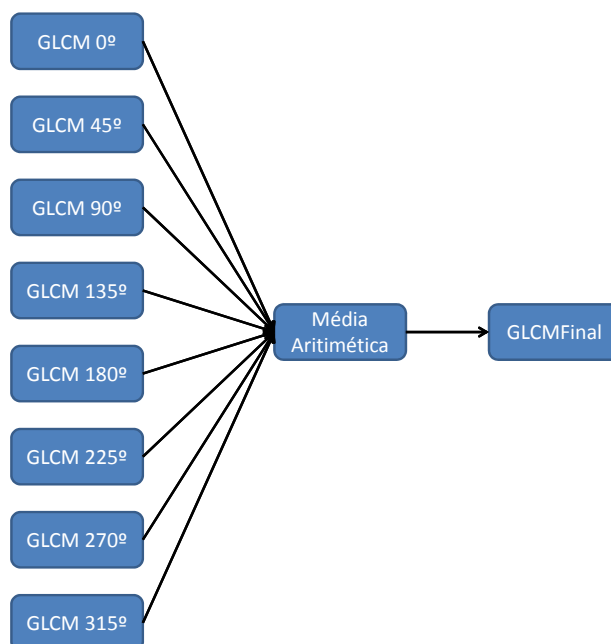
A proposta deste trabalho é usar o algoritmo FuzzyDT com a seguinte combinação de características: homogeneidade, correlação, energia, rede de pigmentos, estrias, branco, vermelho, marrom escuro, azulado e preto.

5.5.1 Descrição dos Modelos de Classificação

Utilizando como entrada as características selecionadas, o algoritmo é treinado e é gerado o seguinte conjunto com 13 regras:

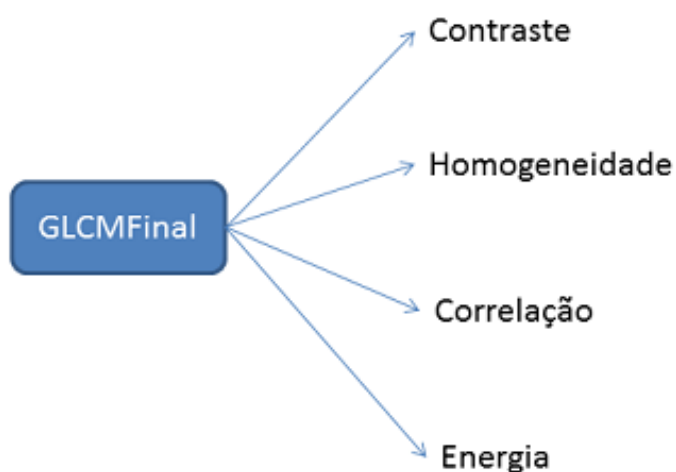
1. SE correlacao é baixa E rede de pigmentos é baixa então é MELANOMA
2. SE correlacao é média E rede de pigmentos é baixa então é MELANOMA

Figura 16 – Extração da matriz GLCM.



Fonte: Autoria Própria

Figura 17 – Extração da matriz GLCM.



Fonte: Autoria Própria

3. SE correlacao é alta E rede de pigmentos é baixa E azulado é baixa então é NEVO ATÍPICO
4. SE correlacao é alta E rede de pigmentos é baixa E azulado é média então é NEVO ATÍPICO
5. SE homogeneidade é baixa E correlacao é alta E rede de pigmentos é baixa E azulado é alta E preto é baixa então é NEVO ATÍPICO
6. SE homogeneidade é média E correlacao é alta E rede de pigmentos é baixa E azulado é alta E preto é baixa então é MELANOMA
7. SE homogeneidade é alta E correlacao é alta E rede de pigmentos é baixa E braco é baixa E azulado é alta e preto é baixa então é NEVO ATÍPICO
8. SE homogeneidade é alta E correlacao é alta E rede de pigmentos é baixa E braco é média E azulado é alta E preto é baixa então é NEVO ATÍPICO
9. SE homogeneidade é alta E correlacao é alta E rede de pigmentos é baixa E braco é alta E azulado é alta E preto é baixa então é MELANOMA
10. SE correlacao é alta E rede de pigmentos é baixa E azulado é alta E preto é média então é MELANOMA
11. SE correlacao é alta E rede de pigmentos é baixa E azulado é alta E preto é alta então é MELANOMA
12. SE rede de pigmentos é média então é NEVO COMUM
13. SE rede de pigmentos é alta então é NEVO COMUM

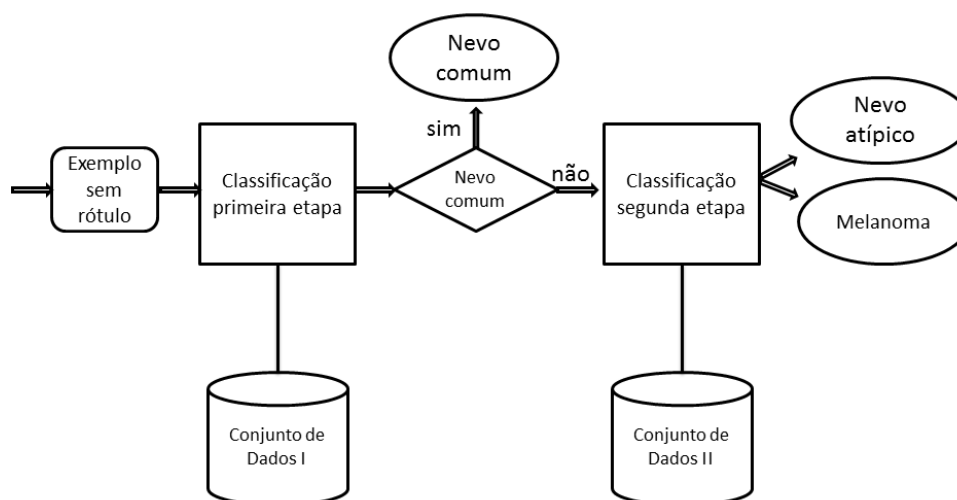
Por fim, baseando-se nessas regras, os exemplos são rotulados em três grupos diferentes: nevo comum, nevo atípico ou melanoma. Os experimentos realizados mostram que com essa combinação de características o algoritmo FuzzyDT obtém 100% de precisão.

5.5.2 Proposta de Classificação em Duas Etapas

Apesar da classificação direta das imagens ter obtido precisão máxima (100%) foram testadas a classificação em 2 etapas. Na 1ª etapa os exemplos são rotulados em nevo comum e nevo não comum e o FDT é usado. Na segunda etapa, os exemplos são rotulados como nevo não comum são classificados entre nevo atípico ou melanoma. A Figura 18 o processo de classificação em duas etapas.

Essa proposta se baseia na hipótese de que os atributos mais adequados para se classificar exemplos nevo comum e nevo não comum podem ser diferentes dos que

Figura 18 – Arquitetura geral da classificação em dois níveis.



Fonte: Autoria Própria

conseguem classificar entre nevo atípico ou melanoma. Assim, dois exemplos diferentes são gerados. Os experimentos realizados são descritos no próximo capítulo.

5.6 CONSIDERAÇÕES FINAIS

Neste capítulo, foi apresentada a proposta para a classificação de lesões de pele, usando características de forma, cor e textura com o algoritmo FuzzyDT.

No próximo capítulo, são mostrados os experimentos realizados, e uma análise comparativa dos resultados, por meio de gráficos e tabelas.

6 EXPERIMENTOS E ANÁLISE DOS RESULTADOS


Neste capítulo são apresentados todos os experimentos realizados, bem como a técnica utilizada para a seleção de características.

6.1 SELEÇÃO DE CARACTERÍSTICAS

O presente trabalho propõe um algoritmo para selecionar características, verificando dentre todas as combinações de características possíveis, o classificador obtém o melhor resultado. Essa proposta se baseia no uso de um Wrapper (CARVALHO, 2011), que testa todas as combinações de atributos com base nos resultados do algoritmo de classificação usado. Logo, por se tratar de um conjunto de dados composto por 16 características, com cada classificador, esse algoritmo compara 65.536 combinações de características.

Para isso, foi criado um vetor de 16 posições para representar o conjunto de características, sendo a primeira característica representada pela primeira posição do vetor, a segunda pela segunda posição, e assim por diante, até a décima sexta posição, como representado na Figura 19.

Figura 19 – Vetor de Características.




Fonte: Autoria Própria

Esse vetor é binário, sendo que o valor 0 (zero), indica a ausência da característica, e o valor 1 (um), a presença da característica, como ilustra a Figura 20.

Na Figura 20, a primeira, a quinta e a última posição estão com valor 1 e as demais posições com 0, logo, quando utilizada a combinação mostrada na figura, serão usadas as seguintes características: contraste, assimetria e preto.

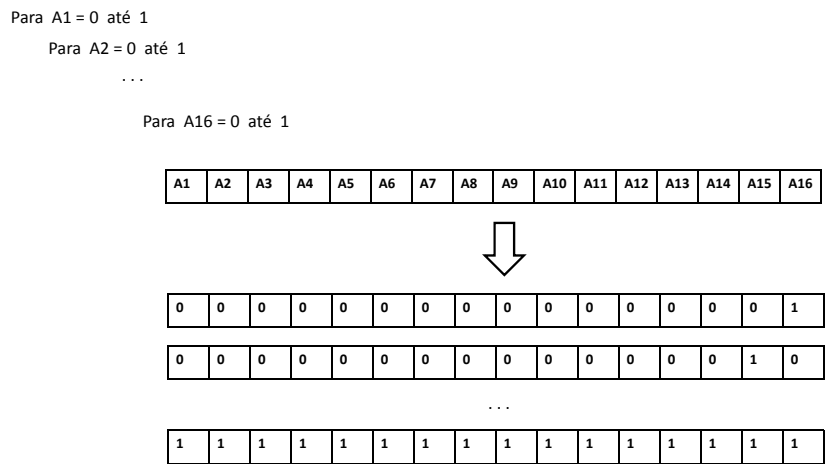
Figura 20 – Vetor de características utilizando três características.



Fonte: Autoria Própria

Ainda com relação a implementação do *wrapper*, para executar todas as possibilidades possíveis, foram feitos 16 laços *for* aninhados, todos variando de um a dois. Dessa forma, as instruções contidas no laço mais interno irão executar 65.536 vezes (número de combinações de características possíveis). A Figura 21 ilustra a interação dos laços com o vetor de características, na qual o vetor varia da posição 000...001, usando apenas uma característica, até a posição 111...111, usando todas as características.

Figura 21 – Interação dos laços com o vetor de características.



Fonte: Autoria Própria

Dessa forma, no laço mais interno, basta executar três ações: i) carregar o conjunto de dados com todas as características, ii) atualizá-lo de acordo com o vetor de características

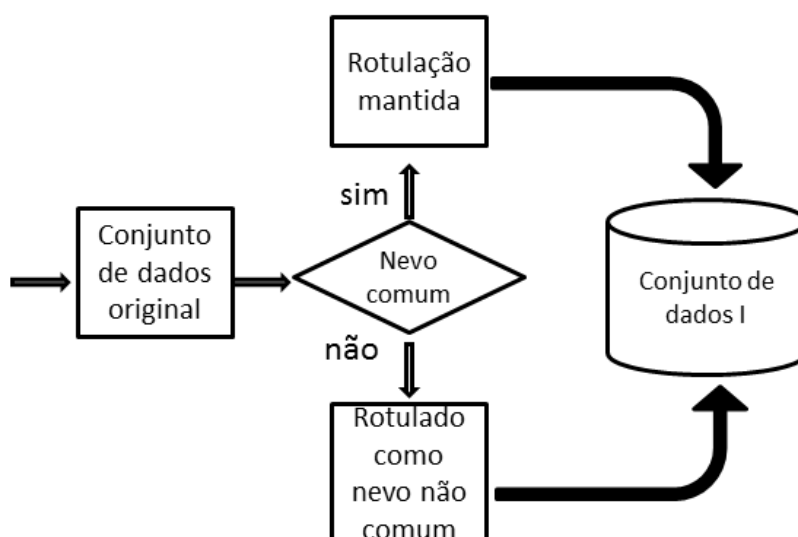
e, por fim, iii) executar o classificador com o conjunto de dados atualizado.

6.2 CLASSIFICAÇÃO EM DUAS ETAPAS

Na classificação em duas etapas, ou seja, classificação da primeira etapa entre exemplos com rótulos nevo comum e nevo não comum, e na segunda etapa, classificação dos exemplos, rotulados como nevo comum na primeira etapa, como nevo atípico ou melanoma.

Por ser utilizada no primeiro nível, o conjunto de dados I foi gerado levando em consideração apenas duas classes: nevo comum e nevo não comum. Para isso, os exemplos cujos rótulos são nevo comum, são mantidos sem alteração, porém, aos exemplos rotulados como nevo atípico ou melanoma, foi atribuída uma nova classe, chamada de nevo não comum, como ilustrado na Figura 22.

Figura 22 – Geração do conjunto de dados I.



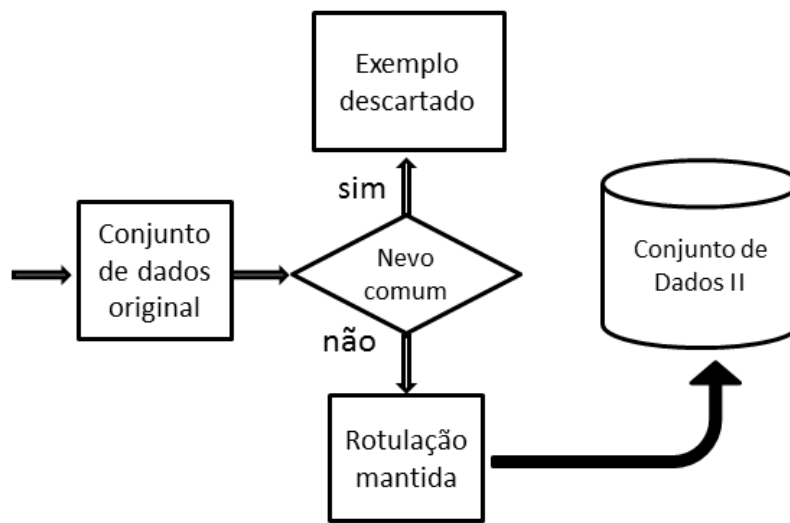
Fonte: Autoria Própria

A Figura 22 mostra que, partindo do conjunto de dados original, cujo os exemplos são classificados como nevo comum, nevo atípico ou melanoma, os exemplos são analisados, e se for nevo comum, é mantida a rotulação e o exemplo é adicionado à base de conhecimento. Caso contrário, se o exemplo for nevo atípico ou melanoma, a rotulação é alterada para nevo não comum e os exemplos são adicionados à base de conhecimento. Logo, como originalmente o conjunto de dados é formado por 200

imagens, sendo divididas em 80 nevo comum, 80 nevo atípico e 40 melanoma, o conjunto de dados I ficou com 80 nevo comum e 120 nevo não comum.

Como na classificação do segundo nível são analisados apenas os exemplos de nevo não comum, ou seja nevo atípico ou melanoma, a única alteração feita no conjunto de dados original foi a eliminação dos exemplos de nevo comum, pois os mesmos já são classificados no primeiro nível. Assim, a geração do conjunto de dados II, foi feita como ilustrado na Figura 23.

Figura 23 – Geração do conjunto de dados II.



Fonte: Autoria Própria

Com relação à quantidade de exemplos, esse conjunto de dados reduziu a quantidade de imagens para 120, sendo 80 nevos atípicos e 40 melanomas.

6.2.1 Experimentos de Classificação

Nos experimentos realizados foram utilizados o algoritmo FuzzyDT, disponibilizado por (CINTRA; CAMARGO, 2010), e outros 20 disponíveis no WEKA (WEKA, 2015), sendo estes: BayesNet, NaiveBayes, NaiveBayesUpdateable, MultiLayerPeceptron (MLP), SMO, Logistic, SimpleLogistic, IBK, KStar, LWL, DecisionStump, J48, LMT, RandomForest, RandomTree, REPTree, DecisionTable, JRip, OneR e PART.

Com relação à execução desses algoritmos, para os algoritmos disponíveis no WEKA, foram usadas as configurações padrão dos mesmos. Para o FuzzyDT foi também utilizadas as configurações padrão que são: três conjuntos fuzzy definindo cada atributo e poda com 25% de confiança. Foi utilizada a técnica de amostragem *10-fold cross validation*.

Para a seleção de atributos, foi desenvolvido um algoritmo que gera os conjuntos de dados com as possíveis combinações de atributos.

Os experimentos realizados são listados a seguir.

1. Classificação usando três classes (nevo comum, nevo atípico e melanoma)

- Experimentos com todos os atributos de forma e cor;
- Experimentos com todos os atributos de textura;
- Experimentos com todos os atributos de forma, cor e textura;
- Experimentos com seleção de atributos de forma e cor;
- Experimentos com seleção de atributos de textura;
- Experimentos com seleção de atributos de forma, cor e textura.

2. Classificação em duas etapas

- 1ª etapa - experimentos com classificação em duas classes (nevo comum e nevo não comum) com todos os atributos.
- 2ª etapa - experimentos com classificação em duas classes (nevo atípico e melanoma) com todos os atributos.
- 1ª etapa - experimentos com classificação em duas classes (nevo comum e nevo não comum) com seleção de atributos.
- 2ª etapa - experimentos com classificação em duas classes (nevo atípico e melanoma) com seleção de atributos.

Nas seções a seguir, são descritos experimentos.

6.3 EXPERIMENTOS DE CLASSIFICAÇÃO USANDO AS TRÊS CLASSES ORIGINAIS (NEVO COMUM, NEVO ATÍPICO E MELANOMA)

O primeiro conjunto de experimentos usou os conjuntos de exemplos rotulados como nevo comum, nevo atípico e melanoma. Para permitir uma análise do poder da classificação dos atributos, foram testados apenas o uso de atributos de forma e cor, de textura e de forma, cor e textura.

6.3.1 Experimentos com Todos os Atributos de Forma e Cor.

Os primeiros experimentos foram feitos utilizando todas as 12 características de forma e cor (assimetria, rede de pigmentos, áreas de regressão, azul esbranquiçado, pontos, estrias, branco, vermelho, marrom claro, marrom escuro, azulado e preto), com os 21 algoritmos, citados anteriormente. A Tabela 3 mostra os resultados obtidos.

Tabela 3 – Resultados da classificação utilizando características de forma e cor.

Grupo	Método	Erro
Bayes	BayesNet	12,5%
Bayes	NaiveBayes	12,5%
Bayes	NaiveBayesUpdateable	12,5%
Function	MLP	11,5%
Function	SMO	8,5%
Function	Logistic	10,0%
Function	SimpleLogistic	8,5%
Lazy	IBK	9,5%
Lazy	KStar	9,5%
Lazy	LWL	18,5%
Trees	DecisionStump	21,5%
Trees	J48	12,5%
Trees	LMT	9,0%
Trees	RandomForest	10,5%
Trees	RandomTree	10,0%
Trees	REPTree	11,5%
Trees	FuzzyDT	10,0%
Rules	DecisionTable	10,0%
Rules	JRip	9,5%
Rules	OneR	21,5%
Rules	PART	9,0%

Fonte: Autoria Própria

Com exceção do OneR e do LWL, que obtiveram erros de 21,50% e 18,50%, respectivamente, os algoritmos testados obtiveram resultados com erro variando entre 8,50%, o SMO e o SimpleLogistic, e 12,50%, os três algoritmos bayesianos, ficando os algoritmos com uma média de erro de 11,83%.

6.3.2 Experimentos com Todos os Atributos de Textura.

Visando uma comparação com os valores obtidos com as características de forma e cor, foram feitos experimentos com as 4 características de texturas: contraste, homogeneidade, correlação e energia. A Tabela 4 mostra os resultados.

Os resultados obtidos com o conjunto de dados, composto apenas de características de textura, ficaram abaixo dos obtidos com a base composta por informações de forma e cor. Com o erro médio de 54,86%, esse conjunto de características piorou o resultado anteriormente obtido em mais de 40,0%.

Tabela 4 – Resultados da classificação utilizando características de textura.

Grupo	Método	Erro
Bayes	BayesNet	54,5%
Bayes	NaiveBayes	52,5%
Bayes	NaiveBayesUpdateable	52,5%
Function	MLP	55,0%
Function	SMO	55,5%
Function	Logistic	54,0%
Function	SimpleLogistic	52,5%
Lazy	IBK	53,5%
Lazy	KStar	54,0%
Lazy	LWL	55,5%
Trees	DecisionStump	60,0%
Trees	J48	59,0%
Trees	LMT	52,5%
Trees	RandomForest	52,5%
Trees	RandomTree	58,5%
Trees	REPTree	56,5%
Trees	FuzzyDT	50,0%
Rules	DecisionTable	57,0%
Rules	JRip	51,0%
Rules	OneR	57,0%
Rules	PART	58,5%

Fonte: Autoria Própria

6.3.3 Experimentos com Todos os Atributos de Forma, Cor e Textura.

Diante do baixo resultado obtido pela classificação utilizando apenas as características de textura, contraste, homogeneidade, correlação e energia, na tentativa de melhorar os resultados, foi criado um conjunto de dados com a junção das características de forma, cor e textura. Assim, de posse desse novo conjunto de características, foram feitos outros experimentos, utilizando os mesmos algoritmos já citados nos experimentos anteriores. A Tabela 5 mostra os resultados obtidos pelos classificadores com esse novo conjunto de características.

Com relação ao erro médio obtido pelos algoritmos, esse novo conjunto de características possibilitou uma diminuição de 0,19%, quando comparado ao uso das características de forma e cor. Com relação às características de texturas, a combinação dos três tipos de características possibilitou uma melhora de 31,5% na precisão. Ainda de acordo com os resultados obtidos, a melhor contribuição do uso desses três tipos de características se deu individualmente, visto que alguns algoritmos, como o randomForest e o FuzzyDT, conseguiram melhorar a precisão em 3,0% e 5,0%, respectivamente, ficando assim, acima do atingido com o uso das características separadamente.


A Figura 24 mostra o resumo dos comportamentos individuais dos 21 algoritmos testados, trazendo o erro obtido por cada, quando utilizado as três combinações de características diferentes: Forma e cor (barra azul), textura (barra verde) e forma, cor e textura (barra vermelha).

Tabela 5 – Resultados da classificação utilizando características de forma, cor e textura.

Grupo	Método	Erro
Bayes	BayesNet	9,5%
Bayes	NaiveBayes	9,5%
Bayes	NaiveBayesUpdateable	9,5%
Function	MLP	10,0%
Function	SMO	7,0%
Function	Logistic	11,0%
Function	SimpleLogistic	10,5%
Lazy	IBK	11,0%
Lazy	KStar	17,5%
Lazy	LWL	19,5%
Trees	DecisionStump	21,5%
Trees	J48	11,5%
Trees	LMT	10,0%
Trees	RandomForest	8,0%
Trees	RandomTree	13,5%
Trees	REPTree	11,5%
Trees	FuzzyDT	5,0%
Rules	DecisionTable	9,0%
Rules	JRip	7,5%
Rules	OneR	21,5%
Rules	PART	9,0%

Fonte: Autoria Própria

Figura 24 – Comparação dos resultados obtidos pelos 21 algoritmos utilizando os três conjuntos de dados diferentes.



Fonte: Autoria Própria

6.3.4 Experimentos com Seleção de Atributos de Forma e Cor.

Os experimentos com seleção de características foram feitos partindo do conjunto de imagens com todas as características de forma e cor (assimetria, rede de pigmentos, áreas de regressão, azul esbranquiçado, pontos, estrias, branco, vermelho, marrom claro, marrom escuro, azulado e preto). As melhores combinações para cada algoritmo são mostradas na Tabela 6.

Tabela 6 – Melhores combinações de características de forma e cor.

	Assimetria	Rede de Pigmentos	Áreas de Regressão	Azul Esbranquiçado	Pontos	Estrias	Branco	Vermelho	Marrom Claro	Marrom Escuro	Azulado	Preto
BayesNet		⊗		⊗								⊗
NaiveBayes	⊗	⊗		⊗		⊗	⊗		⊗			⊗
NaiveBayesUpdateable	⊗	⊗		⊗		⊗	⊗		⊗			⊗
MLP	⊗	⊗		⊗			⊗	⊗	⊗	⊗		⊗
SMO	⊗	⊗	⊗	⊗	⊗	⊗			⊗	⊗		⊗
Logistic	⊗	⊗		⊗			⊗		⊗	⊗		⊗
SimpleLogistic	⊗	⊗		⊗			⊗		⊗	⊗		⊗
IBK	⊗	⊗	⊗	⊗		⊗		⊗	⊗	⊗		⊗
KStar	⊗	⊗		⊗				⊗	⊗	⊗		⊗
LWL		⊗		⊗								
DecisionStump		⊗										
J48		⊗		⊗								
LMT	⊗	⊗		⊗			⊗		⊗	⊗	⊗	⊗
RandomForest	⊗	⊗		⊗			⊗		⊗			⊗
RandomTree		⊗		⊗						⊗		⊗
REPTree		⊗		⊗					⊗			
FuzzyDT	⊗	⊗					⊗				⊗	⊗
DecisionTable		⊗		⊗								
JRip	⊗	⊗		⊗							⊗	⊗
OneR		⊗										
PART	⊗	⊗		⊗					⊗			⊗

Fonte: Autoria Própria

Com relação às características, de acordo com os resultados, as características de forma e cor mais utilizadas detre os algoritmos testados são: assimetria, rede de pigmentos, azul esbranquiçado, marrom claro e marrom escuro. Por outro lado, as menos utilizadas são: pontos, estrias, vermelho e azulado.

A Tabela 7, mostra o desempenho de cada algoritmo utilizando as melhores combinações encontradas de características de forma e cor.

Quando comparado com os resultados obtidos utilizando todas as características presentes no conjunto de dados, a seleção das características proporcionou uma melhora média de 2,5% no desempenho dos algoritmos, mostrando assim a importância de se combinar características para obter melhores resultados. Com esta seleção, 18 dos 21 algoritmos testados tiveram melhores resultados, com destaque para o LWL, que

Tabela 7 – Resultados obtidos na classificação utilizando as características selecionadas de forma e cor descritas na Tabela 6.

Grupo	Método	Erro
Bayes	BayesNet	9,5%
Bayes	NaiveBayes	9,5%
Bayes	NaiveBayesUpdateable	9,5%
Function	MLP	6,0%
Function	SMO	7,5%
Function	Logistic	6,5%
Function	SimpleLogistic	6,5%
Lazy	IBK	6,0%
Lazy	KStar	6,5%
Lazy	LWL	10,0%
Trees	DecisionStump	21,5%
Trees	J48	10,0%
Trees	LMT	6,5%
Trees	RandomForest	6,0%
Trees	RandomTree	7,5%
Trees	REPTree	10,0%
Trees	FuzzyDT	5,0%
Rules	DecisionTable	10,0%
Rules	JRip	8,0%
Rules	OneR	21,5%
Rules	PART	6,5%

Fonte: Autoria Própria

conseguiu diminuir o erro em 8,5% e para o FuzzyDT que obteve o menor erro entre os comparados (5,0%). A Figura 25 mostra o gráfico com esta comparação.

6.3.5 Experimentos com combinação de atributos de textura.

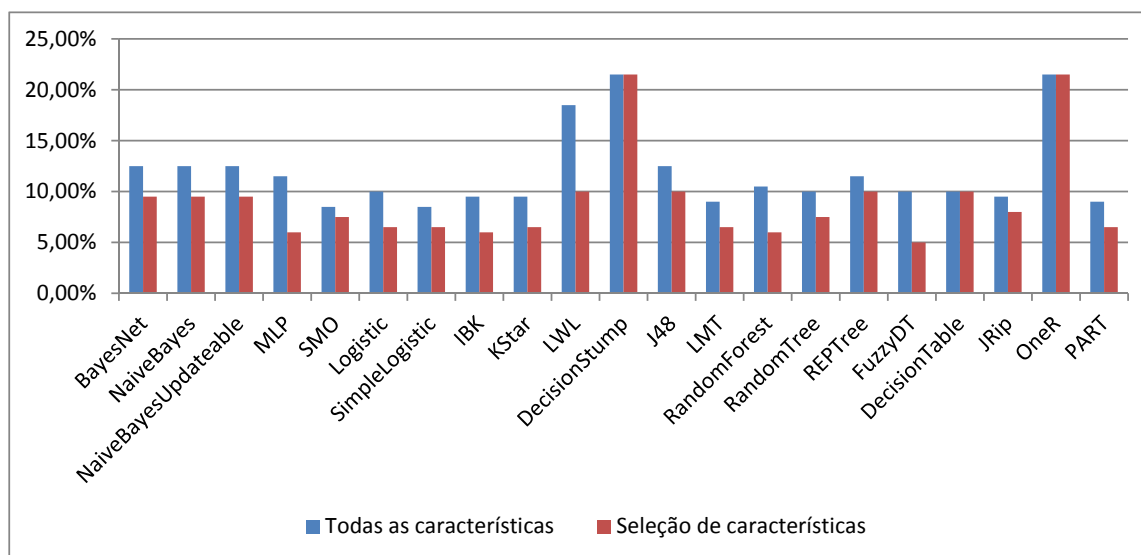
Além de extraídas as melhores combinações com o conjunto de dados que traz informações de forma e cor, foram verificadas as melhores combinações quando levadas em consideração as quatro características de textura. A Tabela 8 mostra essas combinações.

A Tabela 9, mostra os valores obtidos pelos algoritmos quando utilizadas as combinações detalhadas anteriormente.

Apesar dos erros continuarem altos, a seleção de características obteve uma melhora com relação aos valores obtidos quando foram utilizadas todas as características presentes no conjunto de dados. A Figura 26 mostra o gráfico que compara os desempenhos dos algoritmos nas duas situações. As barras azuis mostram os erros encontrados pelos algoritmos utilizando as quatro características, e as barras vermelhas quando utilizada a combinação selecionada.

Não diferente da situação anterior, em boa parte dos algoritmos a combinação de características obteve melhoras. Neste caso, a seleção proporcionou uma diminuição no erro médio de 3,71%, com destaque para o RandomTree, que reduziu o erro de 58,5% para 50,5%.

Figura 25 – Comparação dos resultados obtidos na classificação em três classes utilizando todas as características de forma e cor, com a utilização da seleção de características.



Fonte: Autoria Própria

6.3.6 Experimentos com seleção de atributos de forma, cor e textura.

Por fim, foram feitos os testes com o conjunto de dados composto por características de forma, cor e textura. As combinações encontradas estão listadas na Tabela 10.

Com relação às características, de acordo com os resultados, as características de forma, cor e texturas mais utilizadas entre os algoritmos testados são: assimetria, rede de pigmentos, azul esbranquiçado, preto e correlação. Por outro lado, as menos utilizadas são: pontos, estrias, vermelho e áreas de regressão.

A Tabela 11, mostra os valores obtidos pelos algoritmos quando utilizadas as combinações detalhadas anteriormente.

A Figura 27 mostra uma comparação entre a classificação utilizando todas as características do conjunto de dados composto por informações de forma, cor e textura, e a classificação utilizando as características selecionadas, a qual reduziu o erro médio de 11,80% para 7,92%, na classificação utilizando os três tipos de características.

Os resultados obtidos com essa comparação reforçam a importância da seleção de características para a classificação. Dessa vez, utilizando a combinação de características de forma, cor e textura, a seleção não só mostrou o seu ganho, mais também mostrou a

Tabela 8 – Melhores combinações de características para classificação em três classes utilizando características de textura.

	Contraste	Homogeneidade	Correlação	Energia
BayesNet	⊕	⊕	⊕	⊕
NaiveBayes		⊕	⊕	
NaiveBayesUpdateable		⊕	⊕	
MLP		⊕	⊕	
SMO	⊕		⊕	⊕
Logistic	⊕		⊕	
SimpleLogistic	⊕			
IBK				⊕
KStar		⊕	⊕	
LWL		⊕		
DecisionStump			⊕	
J48		⊕		
LMT			⊕	
RandomForest			⊕	
RandomTree				⊕
REPTree	⊕	⊕	⊕	
FuzzyDT		⊕	⊕	⊕
DecisionTable	⊕		⊕	
JRip	⊕		⊕	
OneR			⊕	
PART		⊕		

Fonte: Autoria Própria

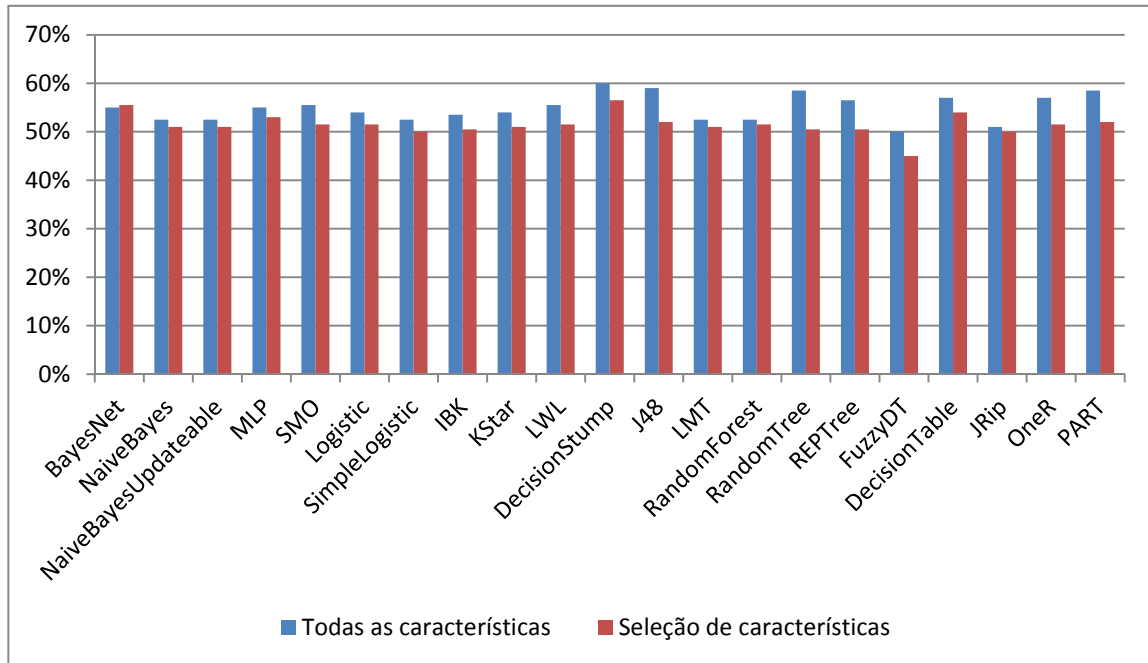
Tabela 9 – Resultados obtidos na classificação em três classes utilizando as melhores características de textura.

Grupo	Método	Erro
Bayes	BayesNet	55,0%
Bayes	NaiveBayes	51,0%
Bayes	NaiveBayesUpdateable	51,0%
Function	MLP	53,0%
Function	SMO	51,5%
Function	Logistic	51,5%
Function	SimpleLogistic	50,0%
Lazy	IBK	50,5%
Lazy	KStar	51,0%
Lazy	LWL	51,5%
Trees	DecisionStump	56,5%
Trees	J48	52,0%
Trees	LMT	51,0%
Trees	RandomForest	51,5%
Trees	RandomTree	50,5%
Trees	REPTree	50,5%
Trees	FuzzyDT	45,0%
Rules	DecisionTable	54,0%
Rules	JRip	50,0%
Rules	OneR	51,5%
Rules	PART	52,0%

Fonte: Autoria Própria

importância da combinação das características de forma, cor e textura, pois em mais de 75,0% dos casos, os melhores resultados partiram da combinação dessas características.

Figura 26 – Comparação entre resultados obtidos na classificação em três classes utilizando todas as características de texturas e utilizando a melhor combinação delas.



Fonte: Autoria Própria

6.4 CLASSIFICAÇÃO EM DUAS ETAPAS

Os experimentos a seguir foram feitos usando-se todas as características de forma, cor e textura.

6.4.1 Experimentos com classificação em duas classes (nevo comum e nevo não comum) com todos os atributos.

Com classificação feita em dois níveis, os experimentos foram feitos individualmente. A Tabela 12 traz os resultados obtidos na primeira etapa de classificação, utilizando todas as características.

Os resultados obtidos mostraram um erro médio de 3,0%, na classificação da primeira etapa utilizando todas as características, com destaque para o algoritmo FuzzyDT, que classificou corretamente todos os exemplos.

Tabela 10 – Melhores combinações de características para classificação em três classes utilizando características de forma, cor e textura.

	Contraste	Homogeneidade	Correlação	Energia	Assimetria	Rede de Pigmentos	Áreas de Regressão	Azul Esbranquiçado	Pontos	Estrias	Branco	Vermelho	Marrom Claro	Marrom Escuro	Azulado	Preto
BayesNet	⊗		⊗	⊗	⊗	⊗	⊗	⊗			⊗				⊗	⊗
NaiveBayes			⊗	⊗	⊗	⊗		⊗		⊗	⊗		⊗			⊗
NaiveBayesUpdateable			⊗	⊗	⊗	⊗		⊗		⊗	⊗		⊗			⊗
MLP			⊗		⊗	⊗	⊗	⊗					⊗	⊗		⊗
SMO			⊗	⊗	⊗	⊗		⊗	⊗		⊗		⊗			⊗
Logistic				⊗	⊗	⊗		⊗	⊗		⊗		⊗			⊗
SimpleLogistic				⊗	⊗	⊗		⊗					⊗	⊗		⊗
IBK			⊗		⊗	⊗	⊗	⊗		⊗	⊗	⊗	⊗	⊗		⊗
KStar		⊗			⊗	⊗	⊗	⊗		⊗			⊗	⊗	⊗	⊗
LWL		⊗				⊗	⊗	⊗								
DecisionStump						⊗										
J48	⊗	⊗				⊗		⊗						⊗		
LMT					⊗	⊗		⊗			⊗		⊗	⊗	⊗	⊗
RandomForest	⊗		⊗			⊗	⊗	⊗	⊗			⊗	⊗	⊗	⊗	
RandomTree					⊗	⊗		⊗					⊗	⊗		⊗
REPTree	⊗	⊗				⊗		⊗								
FuzzyDT		⊗	⊗	⊗		⊗				⊗	⊗	⊗		⊗	⊗	⊗
DecisionTable	⊗		⊗			⊗		⊗								
JRip			⊗		⊗	⊗		⊗								
OneR						⊗										
PART	⊗	⊗				⊗		⊗								⊗


Fonte: Autoria Própria

Tabela 11 – Resultados obtidos na classificação em três classes utilizando as melhores características de forma, cor e textura.

Grupo	Método	Erro
Bayes	BayesNet	6,5%
Bayes	NaiveBayes	6,5%
Bayes	NaiveBayesUpdateable	6,5%
Function	MLP	4,5%
Function	SMO	5,5%
Function	Logistic	6,0%
Function	SimpleLogistic	5,5%
Lazy	IBK	5,5%
Lazy	KStar	6,0%
Lazy	LWL	9,0%
Trees	DecisionStump	21,5%
Trees	J48	6,5%
Trees	LMT	6,5%
Trees	RandomForest	5,5%
Trees	RandomTree	7,5%
Trees	REPTree	7,0%
Trees	FuzzyDT	0,0%
Rules	DecisionTable	8,5%
Rules	JRip	6,5%
Rules	OneR	21,5%
Rules	PART	6,0%

Fonte: Autoria Própria

Figura 27 – Comparação entre resultados obtidos na classificação em três classes utilizando todas as características e utilizando a melhor combinação delas.



Fonte: Autoria Própria

6.4.2 Experimentos com classificação em duas classes (nevo atípico e melanoma) com todos os atributos.

Utilizando todos os atributos, foram iniciados os experimentos e verificadas as presições dos algoritmos na classificação em dois grupos: nevos atípicos e melanoma. A Tabela 13 traz os resultados obtidos nesta etapa.

Nesta etapa, os algoritmos obtiveram um erro médio de 13,27%, tendo o melhor resultado o algoritmo FuzzyDT com 8,3% de erro. Assim, utilizando o melhor algoritmo do primeiro nível, o FuzzyDT (0,0% de erro), e o melhor do segundo nível, que também foi o FuzzyDT (8,3% de erro), o erro total da classificação em dois níveis, utilizando todas as características do conjunto de dados, é de 5,0% de erro (10 imagens classificadas erradas).

6.4.3 1ª etapa - experimentos com classificação em duas classes (nevo comum e nevo não comum) com seleção de atributos.

Na tentativa de encontrar uma combinação que melhorasse os resultados obtidos pelos algoritmos, foram executados testes com a seleção de características na classificação em duas etapas. Para estes, foram utilizados os conjuntos de dados de forma, cor e textura.

Tabela 12 – Resultados obtidos na classificação em duas classes (nevo comum e nevo não comum) da primeira etapa da classificação, utilizando todas as características.

Grupo	Método	Erro
Bayes	BayesNet	3,0%
Bayes	NaiveBayes	3,0%
Bayes	NaiveBayesUpdateable	3,0%
Function	MLP	2,5%
Function	SMO	2,0%
Function	Logistic	2,5%
Function	SimpleLogistic	2,0%
Lazy	IBK	4,5%
Lazy	KStar	7,5%
Lazy	LWL	2,0%
Trees	DecisionStump	2,0%
Trees	J48	2,0%
Trees	LMT	2,0%
Trees	RandomForest	3,0%
Trees	RandomTree	5,5%
Trees	REPTree	2,0%
Trees	FuzzyDT	0,0%
Rules	DecisionTable	2,0%
Rules	JRip	2,0%
Rules	OneR	2,0%
Rules	PART	2,0%

Fonte: Autoria Própria

Tabela 13 – Resultados da classificação em duas classes (nevo atípico e melanoma), utilizando todas as características de forma, cor e textura.

Grupo	Método	Erro
Bayes	BayesNet	10,8%
Bayes	NaiveBayes	10,0%
Bayes	NaiveBayesUpdateable	10,0%
Function	MLP	16,6%
Function	SMO	10,0%
Function	Logistic	11,6%
Function	SimpleLogistic	13,3%
Lazy	IBK	12,5%
Lazy	KStar	18,3%
Lazy	LWL	17,5%
Trees	DecisionStump	13,3%
Trees	J48	13,3%
Trees	LMT	15,0%
Trees	RandomForest	10,8%
Trees	RandomTree	17,5%
Trees	REPTree	13,3%
Trees	FuzzyDT	8,3%
Rules	DecisionTable	16,6%
Rules	JRip	10,8%
Rules	OneR	13,3%
Rules	PART	10,8%

Fonte: Autoria Própria

Com relação ao primeiro nível, apesar de já ter obtido 0,0% de erro com o FuzzyDT, foram feitos testes com os demais algoritmos afim de melhorar os resultados obtidos pelos mesmos. A Tabela 14 traz as melhores combinações de características de cada um

dos algoritmos.

Tabela 14 – Melhores combinações de características para a primeira etapa da classificação com seleção de características.

	Contraste	Homogeneidade	Correlação	Energia	Assimetria	Rede de Pigmentos	Áreas de Regressão	Azul Esbranquiçado	Pontos	Estrias	Branco	Vermelho	Marrom Claro	Marrom Escuro	Azulado	Preto
BayesNet						⊗									⊗	⊗
NaiveBayes						⊗		⊗							⊗	⊗
NaiveBayesUpdateable						⊗		⊗							⊗	⊗
MLP						⊗										
SMO						⊗										
Logistic					⊗	⊗		⊗		⊗		⊗		⊗		
SimpleLogistic						⊗										
IBK						⊗									⊗	⊗
KStar			⊗		⊗		⊗	⊗								
LWL						⊗										
DecisionStump						⊗										
J48						⊗										
LMT						⊗										
RandomForest						⊗		⊗						⊗	⊗	⊗
RandomTree						⊗	⊗	⊗		⊗	⊗		⊗		⊗	⊗
REPTree						⊗										
FuzzyDT						⊗										
DecisionTable						⊗										
JRip						⊗										
OneR						⊗										
PART						⊗										

Fonte: Autoria Própria

De acordo com os resultados obtidos na seleção de características, fica clara a importância que a característica rede de pigmentos, tem nessa classificação. Por outro lado, também é perceptível o quanto as características, contraste, homogeneidade, energia, pontos e branco, não sendo usadas em nenhuma das classificações.

A Tabela 15, mostra os resultados obtidos pelos algoritmos, quando utilizadas as características determinadas na Tabela 14.

A seleção de características possibilitou uma diminuição média dos erros de 1,36%, passando de 3,0% para 1,64% este valor, o que reforça a importância da seleção de características. A Figura 28 mostra a comparação entre a classificação da primeira etapa utilizando todas as características, com a classificação da primeira etapa usando as características selecionadas.


Como pode perceber na Figura 28 em 10 dos 21 algoritmos a seleção de características melhorou o resultado da classificação, com destaque para o Kstar que reduziu o erro de 8,5% para 1,0%.

Tabela 15 – Resultado da classificação na primeira etapa utilizando as características selecionadas.

Grupo	Método	Erro
Bayes	BayesNet	1,5%
Bayes	NaiveBayes	1,5%
Bayes	NaiveBayesUpdateable	1,5%
Function	MLP	2,0%
Function	SMO	2,0%
Function	Logistic	1,0%
Function	SimpleLogistic	2,0%
Lazy	IBK	1,5%
Lazy	KStar	1,0%
Lazy	LWL	2,0%
Trees	DecisionStump	2,0%
Trees	J48	2,0%
Trees	LMT	2,0%
Trees	RandomForest	1,5%
Trees	RandomTree	1,0%
Trees	REPTree	2,0%
Trees	FuzzyDT	0,0%
Rules	DecisionTable	2,0%
Rules	JRip	2,0%
Rules	OneR	2,0%
Rules	PART	2,0%

Fonte: Autoria Própria

Figura 28 – Comparação dos resultados obtidos na primeira etapa da classificação, quando utilizadas todas as características e apenas as selecionadas.



Fonte: Autoria Própria

6.4.4 2ª etapa - experimentos com classificação em duas classes (nevo atípico e melanoma) com seleção de atributos.

A Tabela 16 mostra quais as melhores características para cada algoritmo na classificação em duas classes (nevo comum e melanoma) com seleção de características.

Tabela 16 – Resultados obtidos na segunda etapa da classificação em duas classes, utilizando as características selecionadas.

	Contraste	Homogeneidade	Correlação	Energia	Assimetria	Rede de Pigmentos	Áreas de Regressão	Azul Esbranquiçado	Pontos	Estrias	Branco	Vermelho	Marron Claro	Marron Escuro	Azulado	Preto
BayesNet				⊗	⊗			⊗								
NaiveBayes			⊗	⊗	⊗			⊗			⊗					⊗
NaiveBayesUpdateable			⊗	⊗	⊗			⊗			⊗					⊗
MLP			⊗		⊗	⊗		⊗			⊗		⊗	⊗		⊗
SMO		⊗		⊗	⊗	⊗		⊗			⊗		⊗	⊗		⊗
Logistic		⊗			⊗	⊗		⊗			⊗		⊗	⊗		⊗
SimpleLogistic		⊗			⊗	⊗		⊗		⊗		⊗	⊗	⊗		⊗
IBK			⊗		⊗		⊗	⊗			⊗		⊗	⊗	⊗	⊗
KStar		⊗			⊗		⊗	⊗			⊗					⊗
LWL			⊗	⊗	⊗		⊗	⊗			⊗				⊗	
DecisionStump								⊗								
J48	⊗						⊗	⊗	⊗				⊗	⊗		
LMT		⊗			⊗	⊗		⊗		⊗		⊗	⊗			⊗
RandomForest					⊗		⊗	⊗				⊗	⊗	⊗		⊗
RandomTree		⊗	⊗	⊗	⊗		⊗	⊗					⊗		⊗	
REPTree	⊗						⊗	⊗								
FuzzyDT		⊗	⊗	⊗		⊗				⊗	⊗	⊗		⊗	⊗	⊗
DecisionTable		⊗			⊗			⊗							⊗	⊗
JRip	⊗	⊗	⊗		⊗	⊗		⊗	⊗	⊗	⊗	⊗		⊗	⊗	
OneR								⊗								
PART	⊗						⊗	⊗					⊗	⊗		

Fonte: Autoria Própria

Com relação a esta etapa, as características mais importantes são: azul esbranquiçado e assimetria. Enquanto que as menos utilizadas são pontos e estrias.

A Tabela 17, mostra os resultados obtidos pelos algoritmos, quando utilizadas as características determinadas na Tabela 16.

A seleção de características possibilitou uma diminuição média dos erros de 5,17%, passando de 13,27% para 8,10% este valor. A Figura 29 mostra a comparação entre os resultados obtidos quando utilizadas todas as características e quando utilizadas as selecionadas.

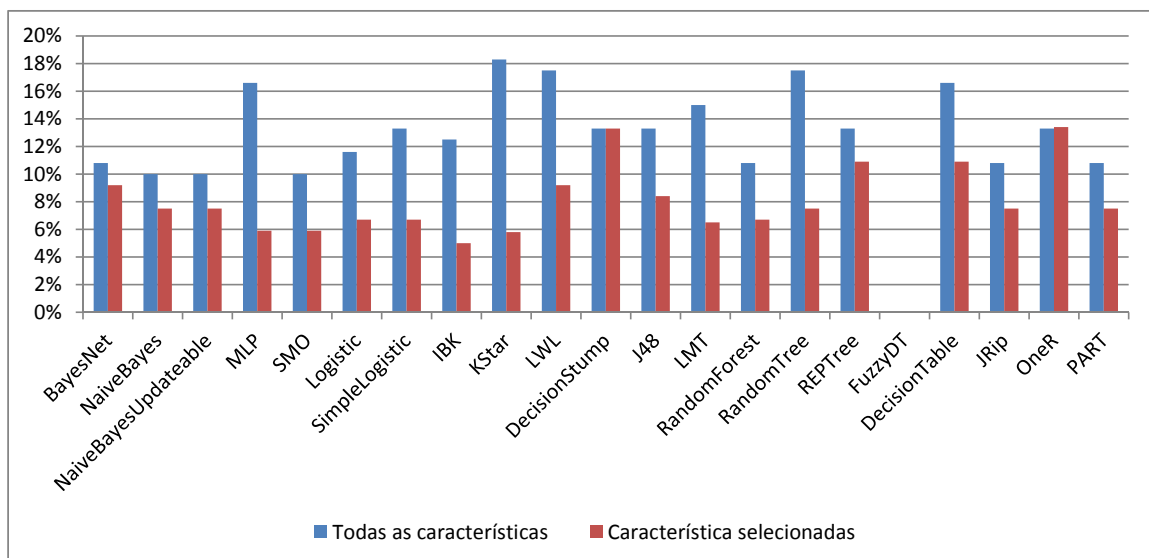
Essa comparação mostra novamente a importância da utilização das características de forma, cor e textura, pois em mais de 80,0% dos casos as melhores combinações utilizam características desses três tipos, bem como o ganho relacionado a seleção das características, pois reduziu o erro em 5,17%.

Tabela 17 – Resultados obtidos na classificação em duas classes (nevo atípico e melanoma) utilizando as características selecionadas.

Grupo	Método	Erro
Bayes	BayesNet	9,2%
Bayes	NaiveBayes	7,5%
Bayes	NaiveBayesUpdateable	7,5%
Function	MLP	5,9%
Function	SMO	5,9%
Function	Logistic	6,7%
Function	SimpleLogistic	6,7%
Lazy	IBK	5,0%
Lazy	KStar	5,8%
Lazy	LWL	9,2%
Trees	DecisionStump	13,3%
Trees	J48	8,4%
Trees	LMT	6,7%
Trees	RandomForest	6,7%
Trees	RandomTree	7,5%
Trees	REPTree	10,9%
Trees	FuzzyDT	0,0%
Rules	DecisionTable	10,9%
Rules	JRip	7,5%
Rules	OneR	13,4%
Rules	PART	7,5%

Fonte: Autoria Própria

Figura 29 – Comparação dos resultados obtidos na segunda etapa da classificação, quando utilizadas todas as características e apenas as selecionadas.



Fonte: Autoria Própria

A Tabela 18 mostra os erro geral da classificação em duas etapas de cada um dos algoritmos.


Tabela 18 – Resultados obtidos na classificação geral feita em duas etapas.

Grupo	Método	Erro
Bayes	BayesNet	7,0%
Bayes	NaiveBayes	6,0%
Bayes	NaiveBayesUpdateable	5,4%
Function	MLP	5,4%
Function	SMO	5,4%
Function	Logistic	5,0%
Function	SimpleLogistic	6,0%
Lazy	IBK	4,5%
Lazy	KStar	4,5%
Lazy	LWL	7,5%
Trees	DecisionStump	10,0%
Trees	J48	7,0%
Trees	LMT	6,0%
Trees	RandomForest	5,5%
Trees	RandomTree	5,5%
Trees	REPTree	8,5%
Trees	FuzzyDT	0,0%
Rules	DecisionTable	8,5%
Rules	JRip	6,5%
Rules	OneR	10,0%
Rules	PART	6,5%

Fonte: Autoria Própria

Além da importância da utilização das características de forma, cor e textura, e da seleção de características, os resultados obtidos mostram o ganho que a classificação em dois níveis obtém, como mostrado na Figura 30, que compara os resultados entre a classificação em duas etapas usando todas as características e a classificação, também em duas etapas, utilizando as características selecionadas.

Figura 30 – Comparação dos resultados obtidos na classificação geral em duas etapas utilizando todas as características e apenas as características selecionadas.




Fonte: Autoria Própria

6.5 ANÁLISE GERAL DOS RESULTADOS

A Figura 31 mostra a evolução dos resultados individuais dos algoritmos em três situações: utilizando todas as características do conjunto de dados de forma e cor, utilizando o conjunto de dados de forma, cor e textura, com seleção de características e classificação em duas etapas utilizando as informações selecionadas do conjunto de dados com forma, cor e textura.

Assim, ao fim de todos os experimentos, foi verificado que a classificação feita em duas etapas com seleção de características proporcionou uma melhora média de 5,55% no resultado individual dos algoritmos, quando comparada com a classificação em três classes utilizando todas as características do conjunto de dados de forma e cor.

Figura 31 – Comparação geral dos resultados.



Fonte: Autoria Própria

6.6 CONSIDERAÇÕES FINAIS

Neste capítulo foram detalhados todos os experimentos realizados, sendo os resultados analisados por meio de gráficos para uma melhor visualização. Também foi feito um levantamento dos ganhos obtidos com a pesquisa, com relação aos 21 algoritmos usados, no qual para cada um deles foi mostrado quais as características que proporcionaram a melhor acurácia.

No próximo capítulo, será apresentada as considerações finais do trabalho, mostrando as contribuições da pesquisa, as publicações obtidas com a mesma, como também serão mostrados alguns trabalhos que podem ser realizados partindo deste.

7 CONSIDERAÇÕES FINAIS

Diante do grande número de casos de câncer de pele, diversos pesquisadores vem tentando desenvolver técnicas para aprimorar e acelerar o diagnóstico, visto que, quando detectado precocemente as chances de cura dessa doença aumentam consideravelmente. Uma das formas de realizar o diagnóstico é através da dermatoscopia. Nessa técnica, o médico tem o auxílio do dermatoscópio para analisar as lesões baseando-se em algumas características. Apesar de analisar a lesão de forma ampliada, e das características extraídas serem bem fundamentadas, esse diagnóstico é subjetivo, pois sofre interferência de alguns fatores. Assim tem sido pesquisada a utilidade da análise computacional no auxílio aos profissionais na realização desse tipo de diagnóstico.

Visando melhorar a precisão desse diagnóstico, o presente trabalho propôs uma metodologia para classificação de lesões de pele utilizando o algoritmo FuzzyDT baseando-se em características selecionadas de forma, cor e textura. Além dessa metodologia, também foi proposta uma classificação em dois níveis, no qual o primeiro nível é responsável por separar os exemplos em nevo comum e nevo não comum, e o segundo responsável reclassificar os exemplos que no primeiro momento foram classificados como nevo não comum, em nevo atípico ou melanoma.

7.1 CONTRIBUIÇÕES

Com relação à primeira proposta foram extraídas quatro características de textura das imagens e adicionadas às doze já disponíveis, ficando o novo conjunto de dados com as seguintes características: contraste, correlação, homogeneidade, energia, assimetria, rede de pigmentos, áreas de regressão, azul esbranquiçado, pontos, estrias, branco, vermelho, marrom claro, marrom escuro, azulado e preto.

De posse desse novo conjunto de dados, foram feitos vários experimentos e concluiu-se que a melhor combinação de características para o algoritmo FuzzyDT é: Homogeneidade, Correlação, Energia, Rede de Pigmentos, Estrias, Branco, Vermelho, Marrom Escuro, Azulado e Preto. Utilizando essas dez características como entrada, o algoritmo FuzzyDT obteve 100% de acurácia.

Na tentativa de melhorar os resultados obtidos pelos outros 21 algoritmos testados, foi desenvolvida uma segunda proposta para a classificação, sendo essa feita em duas etapas. Na primeira responsável pela separação das imagens em nevo comum e nevo não comum. Desses, os exemplos classificados como nevo não comum são submetidos a

outra classificação, na qual os exemplos são classificados em nevo atípico ou melanoma, finalizando assim a classificação em duas etapas.

com a classificação em duas etapas também foram obtidos resultados satisfatórios, visto que a diferença de precisão da classificação em um nível utilizando o conjunto de dados com características de forma e cor, com a classificação em dois níveis aqui proposta, foi de 5,55%, e que em 100% dos algoritmos os resultados utilizando as duas etapas com características selecionadas foram melhores.

7.2 TRABALHOS FUTUROS

Como trabalhos futuros, o presente trabalhos propõe:

- **Extração de novas características de texturas:** afim de caracterizar melhor os exemplos e conseqüentemente melhorar a acurácia obtida pelos algoritmos.
- **Desenvolvimento de um algoritmo para seleção de características utilizando meta-heurística:** o desenvolvimento desse algoritmo possibilitará a seleção em um grande número de características, visto que de forma exata não seria possível em tempo computacional.
- **Utilização de comitês de algoritmos juntamente com a seleção de características:** na tentativa de melhorar os resultados já obtidos com os algoritmos individualmente.

7.3 PUBLICAÇÕES

O desenvolvimento desta pesquisa possibilitou a publicação de dois artigos, sendo: Métodos de Processamento de Imagens de Lesões de Pele, publicado e apresentado no EPOCA (Escola Potiguar de Computação e Suas Aplicações) 2014, e o Proposta de Classificador de Lesões de Pele Utilizando Características de Forma, Cor e Textura, publicado e apresentado no EPOCA (Escola Potiguar de Computação e Suas Aplicações) 2015.

No primeiro, sobre processamento de imagens, foram mostrados alguns dos principais métodos de processamento de imagens de lesões de pele encontrados na literatura, a sequência de utilização, bem como a utilização dos mesmos em trabalhos já desenvolvidos.

No segundo artigo, foi mostrada uma proposta para um classificador de lesões de pele utilizando a combinação de características de forma, cor e textura. Nessa proposta foi utilizada a seleção de característica, e mostrada através de gráficos o ganho obtido com essa técnica.

REFERÊNCIAS

- ABUZAGHLEH, O.; BARKANA, B. D.; FAEZIPOUR, M. Skincure: A real time image analysis system to aid in the malignant melanoma prevention and early detection. *Southwest Symposium on Image Analysis and Interpretation (SSIAI)*, 2014. Citado na página 42.
- BEUREN, A. T. et al. Skin melanoma segmentation by morphological approach. *Proceedings of the International Conference on Advances in Computing, Communications and Informatics*, pp.972-978, 2012. Citado 2 vezes nas páginas 20 e 41.
- BREIMAN, L. et al. *Classification and Regression Trees*. [S.l.]: Wadsworth and Brooks, 1984. Citado na página 27.
- CANNY, J. A computation approach to edge detection. *Transactions on pattern analysis and machine intelligence*, Vol. 8, pp.679-698, 1986. Citado 2 vezes nas páginas 20 e 42.
- CARVALHO, A. *INTELIGENCIA ARTIFICIAL: UMA ABORDAGEM DE APRENDIZADO DE MAQUINA*. [S.l.]: LTC, 2011. Citado 6 vezes nas páginas 26, 28, 30, 34, 37 e 53.
- CAVALCANTI, P. G.; SCHARCANSKI, J. A coarse-to-fine approach for segmenting melanocytic skin lesions in standard camera images. *computer methods and programs in biomedicine*, "112", n. "3", p. "684 – 693", 2013. Citado na página 40.
- CELEBI, M. E. Automated quantification of clinically significant colors in dermoscopy images and its application to skin lesion classification. *IEEE SYSTEMS JOURNAL*, 2014. Citado na página 42.
- CELEBI, M. E.; ASLANDOGAN, Y. A.; BERGSTRESSER, P. R. Unsupervised border detection of skin lesion images. *Proceedings of the International Conference on Information Technology: Coding and Computing*, vol. 2, pp.123-128, 2005. Citado 2 vezes nas páginas 18 e 21.
- CELEBI, M. E. et al. Border detection in dermoscopy images using statistical region merging. *Skin Research and Technology*, vol. 14, pp.347-354, 2008. Citado 3 vezes nas páginas 18, 21 e 30.
- CHADWICK, X. et al. Mobile medical applications for melanoma risk assessment: False assurance or valuable tool? *Hawaii International Conference on System Science*, p. 980–984, 2014. Citado na página 44.
- CHIEM, A.; AL-JUMAILY, A.; KHUSHABA, R. N. A novel hybrid system for skin lesion detection. *International Conference on Intelligent Sensors, Sensor Networks and Information*, pp.567-572, 2007. Citado na página 18.
- CINTRA, M. E. *Geração Genética de Regras Fuzzy com Pré-Seleção de Regras Candidatas*. Dissertação (Mestrado) — Universidade Federal de São Carlos, 2007. Citado na página 33.

- CINTRA, M. E. *Genetic Generation of fuzzy Knowledge bases: new perspectives*. Tese (Doutorado) — UNIVERSIDADE de São Paulo, 2012. Citado 3 vezes nas páginas 31, 32 e 33.
- CINTRA, M. E.; CAMARGO, H. de A. Feature subset selection for fuzzy classification methods. *International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems - IPMU - Communications in Computer and Information Science*, v. 80, p. 318327, 2010. Citado 3 vezes nas páginas 30, 33 e 56.
- CUDEK, P.; GRZYMALA-BUSSE, J. W.; HIPPE, Z. S. Melanocytic skin lesion image classification. part i: Recognition of skin lesion. *Conference on Human System Interactions (HSI). 3rd, Rzeszow, p. 251-257, 2010*. Citado na página 20.
- FACON, J. *Morfologia matemática: teoria e exemplos*. [S.l.]: Editora Universitária Champagnat da Pontífica Universidade Católica do Paraná, 1996. Citado na página 19.
- FRANGE, V. M. N.; ARRUDA, L. H. F.; DALDON, P. Érica C. Dermatoscopia: importância para a prática clínica. *Ciências Médicas, Campinas, 18(4)*, p. 209–215, 2009. Citado 2 vezes nas páginas 13 e 14.
- GANZELI, H. S. et al. Skan: Skin scanner – system for skin cancer detection using adaptive techniques. *Latin America Transactions, IEEE (Revista IEEE America Latina)*, p. 206–212, 2011. Citado na página 42.
- GONZALEZ, R. C.; WOODS, R. E. *Processamento digital de imagens*. 3. ed. [S.l.]: Prentice Hall, 2010. Citado 4 vezes nas páginas 17, 18, 19 e 20.
- HARALICK, R. M. Statistical and structural approaches to texture. *Proceedings of the IEEE*, v. 67, n. 5, p. 786–804, 1979. Citado na página 24.
- HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. 2nd. ed. [S.l.]: Prentice Hall PTR, 1998. Citado na página 37.
- HINTZ-MADSEN, M. et al. *A Probabilistic Neural Network Framework For The Detection Of Malignant Melanoma*. [S.l.]: CRC Press, 2001. 141-183 p. Citado na página 38.
- LAU, H. T.; AL-JUMAILY, A. Automatically early detection of skin cancer: study based on neural network classification. *International Conference of Soft Computing and Pattern Recognition, pp.375-380, 2009*. Citado na página 18.
- LEE, T. et al. Dullrazor: A software approach to hair removal from images. *Computers in Biology and Medicine, vol. 27, pp.533-543, 1997*. Citado 2 vezes nas páginas 17 e 21.
- LEO, G. D. et al. Towards an automatic diagnosis system for skin lesions: estimation of blue-whitish veil and regression structures. *International Multi-Conference on Systems, Signals and Devices. 6th, p. 1-6, 2009*. Citado na página 23.
- LEO, G. D. et al. Automatic diagnosis of melanoma: a software system based on the 7-point check-list. *International Conference on System Sciences. p. 1-10., 2010*. Citado na página 23.
- LICHMAN, M. *UCI Machine Learning Repository*. 2013. Disponível em: <<http://archive.ics.uci.edu/ml>>. Citado na página 31.

- LPCC. *Liga Portuguesa Contra o Cancro*. 2015. [Http://www.ligacontracancro.pt/](http://www.ligacontracancro.pt/). Citado na página 13.
- MA, Z. et al. A review of algorithms for medical image segmentation and their applications to the female pelvic cavity. *Computer Methods in Biomechanics and Biomedical Engineering*, v. 13, n. 2, p. 235–246, 2010. Citado na página 19.
- MASOOD, A.; AL-JUMAILY, A. A. Integrating soft and hard threshold selection algorithms for accurate segmentation of skin lesion. *Middle East Conference on Biomedical Engineering (MECBME)*, p. 83–86, 2014. Citado 2 vezes nas páginas 40 e 41.
- MAURYA, R. et al. Glcm and multi class support vector machine based automated skin cancer classification. *International Conference on Computing for Sustainable Global Development (INDIACom)*, 2014. Citado na página 43.
- MENDEL, J. M.; JOHN, R. I. B. Type-2 fuzzy sets made simple. *IEEE Trans. Fuzzy Syst.*, v. 10, n. 2, p. 117-127, 2002. Citado na página 21.
- MENDONÇA, T. et al. Ph2 - a dermoscopic image database for research and benchmarking. *35th International Conference of the IEEE Engineering in Medicine and Biology Society.*, p. 5437–5440, 2013. Citado na página 46.
- MENDOZA, C. S.; SERRANO, C.; ACHA, B. Scale invariant descriptors in pattern analysis of melanocytic lesions. *IEEE International Conference on Image Processing (ICIP)*, p. 4193-4196, 2009. Citado na página 23.
- MITCHELL, T. M. *Machine Learning*. 1. ed. [S.l.]: McGraw-Hill, Inc., 1997. Citado 3 vezes nas páginas 26, 35 e 36.
- MULLER, K. R. et al. Evaluation of patients learning about the abcd rule: a randomized study in southern brazil. *An Bras Dermatol*;84(6):593-8., 2009. Citado na página 22.
- NASER, N. Cutaneous melanoma - a 30-year-long epidemiological study conducted in acity in southern brazil, from 1980-2009. *Anais Brasileiros de Dermatologia*, p. 932–941, 2011. Citado na página 14.
- NEVES, S. C. M.; PELAES, E. G. Estudo e implementação de técnicas de segmentação de imagens. *Revista Virtual de Iniciação Acadêmica da UFPA, Vol 1, No 2*, 2001. Citado na página 19.
- OLIVEIRA, R. B. et al. Classificação de assimetria em lesões de pele por meio de imagens usando máquina de vetor de suporte. *VIII Workshop de Visão Computacional*, 2012. Citado na página 42.
- OTSU, N. A threshold selection method from gray-scale histograms. *IEEE Trans. on Syst. Man. Cybern.*, vol. 9, no. 1, pp. 62–66, 1978. Citado na página 21.
- PEHAMBERGER, H.; STEINER, A.; WOLFF, K. In vivo epiluminescence microscopy of pigmented skin lesions. i. pattern analysis of pigmented skin lesions. *Journal of the American Academy of Dermatology*, v. 17, n. 4, p. 571 – 583, 1987. Citado na página 23.
- PERONA, P.; MALIK, J. Scale-space and edge detection using anisotropic diffusion. *IEEE transactions on pattern analysis and machine intelligence*, vol. 12, pp.629-639, 1990. Citado 2 vezes nas páginas 17 e 19.

PIRES, V. B.; BARCELOS, C. A. Z. Edge detection of skin lesions using anisotropic diffusion. *Seventh International Conference on Intelligent Systems Design and Applications*, pp.363-370, 2007. Citado 2 vezes nas páginas 19 e 22.

PROCIANOY, P. D. d. C. *Correlação entre o diagnóstico clínico, dermatoscópico e histológico de nevos atípicos*. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Sul, 2009. Citado na página 23.

QUINLAN, J. R. Discovering rules by induction from large collections of examples. In: MICHIE, D. (Ed.). *Expert Systems in the Micro-Electronic Age*. [S.l.]: Edinburgh University Press, 1979. p. 168–201. Citado na página 27.

QUINLAN, J. R. *C4.5: Programs for Machine Learning*. [S.l.]: Morgan Kaufmann Publishers Inc., 1993. ISBN 1-55860-238-0. Citado 2 vezes nas páginas 27 e 30.

RANJAN, P. Using texture analysis for medical diagnosis. *Media in Medicine*, p. 28–37, 2012. Citado na página 43.

REZZE, G. G.; Sá, B. C. S. de; NEVES, R. I. Dermoscopy: the pattern analysis. *An Bras Dermatol*;(3):261-8., 2006. Citado na página 23.

RUBEGNI, P. et al. Digital dermoscopy analysis for automated diagnosis of pigmented skin lesions. *Clinics in Dermatology*, v. 20, n. 3, p. 309–312, 2002. Citado na página 39.

RUIZ, D. et al. A decision support system for the diagnosis of melanoma: A comparative approach. *Expert Systems with Applications*, v. 38, n. 12, p. 15217 – 15223, 2011. Citado 2 vezes nas páginas 34 e 43.

RUSSELL, S.; NORVIG, P. *Inteligência artificial*. [S.l.]: CAMPUS - RJ, 2004. Citado 3 vezes nas páginas 27, 34 e 37.

SAHOO, P.; WILKINS, C.; YEAGER, J. Threshold selection using renyis entropy. *Pattern Recognition*, v. 30, n. 1, p.71-84, 1997. Citado na página 21.

SMITH, J. D. M. *Characterisation of the Appearance of Pigmented Skin Lesions*. Tese (Doutorado) — School of Computer Science, The University of Birmingham, UK, 1996. Citado na página 22.

SONKA, M.; HLAVAC, V.; BOYLE, R. *Image processing, analysis, and machine vision*. 2. ed. [S.l.]: PWS, 1998. Citado na página 20.

SOYER, H. et al. Early diagnosis of malignant melanoma by surface microscopy. *Lancet*, v. 2, p. 803, 1987. Citado na página 14.

SUPOT, S. Skin lesion detection of dermoscopy images using estimate localization technique. *cFourth International Conference on Communication Systems and Network Technologies*, 2014. Citado na página 18.

VIANA, J. da C. Classificação de tumores de pele através da análise de imagens sem restrições: uma visão geral do processo. *Lusíada. Economia e Empresa*, p. 83–92, 2014. Citado na página 36.

VIEIRA, C. *MATLAB - Curso Completo*. [S.l.]: Fca, 2013. Citado 2 vezes nas páginas 47 e 48.

WEKA. *Weka 3: Data Mining Software in Java*. 2015.
[Http://www.cs.waikato.ac.nz/ml/weka/](http://www.cs.waikato.ac.nz/ml/weka/). Citado na página 56.

WINSTON, P. H. *Artificial Intelligence*. [S.l.]: Addison-Wesley Longman Publishing Co., Inc., 1992. Citado na página 26.

YUKSEL, M. E.; BORLU, M. Accurate segmentation of dermoscopic images by image thresholding based on type-2 fuzzy logic. *IEEE Transactions on fuzzy systems*, v. 17, n. 4, p. 976-982, 2009. Citado 2 vezes nas páginas 20 e 21.