



UNIVERSIDADE
ESTADUAL DE LONDRINA

GABRIEL FILLIPE CENTINI CAMPOS

UMA ABORDAGEM BASEADA EM META-
APRENDIZADO PARA RECOMENDAR ALGORITMOS
DE SEGMENTAÇÃO DE IMAGENS

Londrina
2016

GABRIEL FILLIPE CENTINI CAMPOS

UMA ABORDAGEM BASEADA EM META-
APRENDIZADO PARA RECOMENDAR ALGORITMOS
DESEGMENTAÇÃO DE IMAGENS

Dissertação apresentada ao Programa de
Mestrado em Ciência da Computação da
Universidade Estadual de Londrina para
obtenção do título de Mestre em Ciência da
Computação.

Orientador: Prof.Dr. Sylvio Barbon Jr.

Londrina

2016

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UEL

Campos, Gabriel F. C..

Uma Abordagem Baseada em Meta-Aprendizado para Recomendar Algoritmos de Segmentação de Imagens / Gabriel F. C. Campos. - Londrina, 2016.
63 f. : il.

Orientador: Sylvio Barbon.

Dissertação (Mestrado em Ciência da Computação) - Universidade Estadual de Londrina, Centro de Ciências Exatas, Programa de Pós-Graduação em Ciência da Computação, 2016.

Inclui bibliografia.

1. Recomendação de algoritmos de segmentação - Tese. 2. Meta-aprendizado - Tese.
3. Processamento de imagens - Tese. I. Barbon, Sylvio. II. Universidade Estadual de Londrina. Centro de Ciências Exatas. Programa de Pós-Graduação em Ciência da Computação. III. Título.

GABRIEL FILLIPE CENTINI CAMPOS

UMA ABORDAGEM BASEADA EM META-
APRENDIZADO PARA RECOMENDAR ALGORITMOS
DESEGMENTAÇÃO DE IMAGENS

Dissertação apresentada ao Programa de
Mestrado em Ciência da Computação da
Universidade Estadual de Londrina para
obtenção do título de Mestre em Ciência da
Computação.

BANCA EXAMINADORA

Orientador: Prof.Dr. Sylvio Barbon Jr.
Universidade Estadual de Londrina –
UEL

Prof. Dr. Alan Salvany Felinto
Universidade Estadual de Londrina –
UEL

Prof. Dr. José Alexandre de França
Universidade Estadual de Londrina –
UEL

Prof. Dr. Leonimer Flávio de Melo
Universidade Estadual de Londrina –
UEL

Londrina, 25 de novembro de 2016.

AGRADECIMENTOS

Agradeço a todas as pessoas que de alguma maneira contribuíram com minha formação e à CAPES por financiar meus estudos durante o tempo do programa.

CAMPOS, G. F. C.. **Uma Abordagem Baseada em Meta-Aprendizado para Recomendar Algoritmos de Segmentação de Imagens**. 63 p. Dissertação de Mestrado (Mestrado em Ciência da Computação) – Universidade Estadual de Londrina, Londrina–PR, 2016.

RESUMO

Existem vários algoritmos de segmentação de imagens, porém, não existe um algoritmo que seja adequado para todos os tipos de aplicações envolvendo imagens. Recomendar um algoritmo de segmentação ideal é uma tarefa desafiadora que requer conhecimento sobre o problema e sobre os algoritmos. Nos últimos anos, o Meta-Aprendizado, oriundo do Aprendizado de Máquina, emergiu para contribuir na solução do problema de seleção de algoritmos. Neste trabalho, Meta-Aprendizado foi utilizado para recomendar algoritmos de segmentação de imagens, baseando-se em meta-conhecimento. Experimentos foram realizados em quatro meta-bases (bases de dados de Meta-Aprendizado) diferentes que representam problemas reais, recomendando se três diferentes segmentadores (Otsu, K-means e SVM) são adequados ou não adequados para uma dada imagem. Um conjunto de 44 características baseadas em cor, domínio da frequência, histograma, textura, contraste e qualidade de imagem foi extraído das amostras, para realizar a tarefa de recomendação em diferentes cenários de segmentação. Os resultados mostraram que, em geral, os meta-modelos construídos com o algoritmo *Random Forest* obtiveram alta performance em recomendar o algoritmo de segmentação, se comparados com os meta-modelos construídos por outros oito algoritmos.

Palavras-chave: Recomendação de algoritmos de segmentação. Meta-aprendizado. Processamento de imagens.

CAMPOS, G. F. C.. **A Meta-learning Approach for Recommendation of Image Segmentation Algorithms**. 63 p. Master's Thesis (Master in Science in Computer Science) – State University of Londrina, Londrina–PR, 2016.

ABSTRACT

There are many algorithms for image segmentation, but there is no optimal algorithm for all kind of image applications. To recommend an adequate algorithm for image segmentation is a challenging task that requires knowledge about the problem and the algorithms. In the past years, Meta-Learning has emerged from the Machine Learning research field to help solving the algorithm selection problem. This paper applies Meta-Learning to recommend image segmentation algorithms based on meta-knowledge. We performed experiments in four different meta-databases that represent various real problems, recommending when three different segmentation techniques are adequate or not. A set of 44 features based on color, frequency domain, histogram, texture, contrast and image quality was extracted from images in order to perform the recommending task in different segmentation scenarios. Results show that Random Forest meta-models were able to recommend the segmentation algorithm at the overall scenario with high predictive performance in comparison to other eight algorithms.

Keywords: Segmentation algorithms recommendation. Meta-learning. Image processing

LISTA DE ILUSTRAÇÕES

| | |
|---|----|
| Figura 3.1 – Exemplo de segmentação por limiarização, com valor de limiar (<i>threshold</i>) 127 | 29 |
| Figura 3.2 – Exemplos de segmentação por <i>clustering</i> utilizando o algoritmo <i>K-means</i> | 31 |
| Figura 3.3 – Algoritmo K-means | 31 |
| Figura 3.4 – Exemplos de segmentação por classificação supervisionada, realizada nos experimentos deste trabalho | 32 |
| Figura 3.5 – Exemplo de hiperplano detectado via algoritmo SVM para um problema de separação linear [1] | 33 |
| Figura 4.1 – Visão geral do modelo proposto | 39 |
| Figura 5.1 – Exemplos de segmentação adequada para cada meta-base: frango , ferida e nuvem | 42 |
| Figura 6.1 – Performance média dos meta-modelos da meta-base ferida de acordo com cinco diferentes medidas: Acurácia Preditiva, Área Abaixo da Curva ROC (AAC), <i>F-Measure</i> , Taxa de Verdadeiros Positivos (VPTaxa) e Taxa de Verdadeiros Negativos (VNTaxa) | 47 |
| Figura 6.2 – Performance média dos meta-modelos da meta-base frango de acordo com cinco diferentes medidas: Acurácia Preditiva, Área Abaixo da Curva ROC (AAC), <i>F-Measure</i> , Taxa de Verdadeiros Positivos (VPTaxa) e Taxa de Verdadeiros Negativos (VNTaxa) | 48 |
| Figura 6.3 – Performance média dos meta-modelos da meta-base nuvem de acordo com cinco diferentes medidas: Acurácia Preditiva, Área Abaixo da Curva ROC (AAC), <i>F-Measure</i> , Taxa de Verdadeiros Positivos (VPTaxa) e Taxa de Verdadeiros Negativos (VNTaxa) | 49 |
| Figura 6.4 – Performance média dos meta-modelos da meta-base completa de acordo com cinco diferentes medidas: Acurácia Preditiva, Área Abaixo da Curva ROC (AAC), <i>F-Measure</i> , Taxa de Verdadeiros Positivos (VPTaxa) e Taxa de Verdadeiros Negativos (VNTaxa) | 50 |
| Figura 6.5 – Valor de <i>Mean Decrease Gini</i> para todas os meta-descritores extraídos dos meta-modelos RF | 51 |
| Figura 6.6 – Predições para cada amostra, levando em conta a meta-base completa (em cima) e as outras três meta-bases separadamente (embaixo) | 53 |
| Figura 6.7 – Amostras problemáticas 18, 25 e 38: originais e segmentadas | 54 |

LISTA DE TABELAS

| | |
|---|----|
| Tabela 5.1 – Lista de todos os descritores de imagens usados como meta-descritores na abordagem proposta | 44 |
| Tabela 5.2 – Especificações principais das meta-bases utilizadas nos experimentos . | 44 |
| Tabela 6.1 – Performance dos meta-modelos gerados pelo algoritmo <i>Random Forest</i> comparada a dos dois <i>baselines</i> : Aleatório e Maioria | 50 |
| Tabela 6.2 – Valor de <i>Mean Decrease Gini</i> dos cinco meta-descritores mais importantes para cada segmentador na meta-base ferida | 51 |
| Tabela 6.3 – Valor de <i>Mean Decrease Gini</i> dos cinco meta-descritores mais importantes para cada segmentador na meta-base frango | 52 |
| Tabela 6.4 – Valor de <i>Mean Decrease Gini</i> dos cinco meta-descritores mais importantes para cada segmentador na meta-base nuvem | 52 |
| Tabela 6.5 – Valor de <i>Mean Decrease Gini</i> dos cinco meta-descritores mais importantes para cada segmentador na meta-base completa | 53 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|--------|---|
| AAC | Área Abaixo da Curva ROC |
| AD | Segmentação Adequada |
| AM | Aprendizado de Máquina |
| avNNet | <i>Neural Networks Using Model Averaging</i> |
| BR | <i>Binary Relevance</i> |
| EME | <i>Measure of Enhancement</i> |
| FFT | <i>Fast Fourier Transform</i> |
| GCF | <i>Global Contrast Factor</i> |
| HSV | <i>Hue, Saturation and Value</i> |
| k-NN | <i>k-Nearest Neighbors</i> |
| LOO-CV | <i>Leave-One-Out Cross-Validation</i> |
| MtA | Meta-Aprendizado |
| NAD | Segmentação Não Adequada |
| NB | <i>Naive Bayes</i> |
| PNG | <i>Portable Network Graphics</i> |
| RF | <i>Random Forest</i> |
| RGB | <i>Red, Green and Blue</i> |
| RNA | Redes Neurais Artificiais |
| ROC | Curva ROC (<i>Receiver Operator Characteristic</i>) |
| ROI | Região de Interesse (<i>Region of Interest</i>) |
| SNM | <i>Statistical Naturalness Measure</i> |
| SVM | <i>Support Vector Machine</i> |
| VC | Visão Computacional |
| VN | Verdadeiro Negativo |

VNTaxa Taxa de Verdadeiros Negativos

VP Verdadeiro Positivo

VPTaxa Taxa de Verdadeiros Positivos

SUMÁRIO

| | | |
|---------|---|----|
| 1 | INTRODUÇÃO | 19 |
| 1.1 | Objetivos | 20 |
| 1.1.1 | Objetivo principal | 20 |
| 1.1.2 | Objetivos específicos | 21 |
| 1.2 | Organização do Trabalho | 21 |
| 2 | TRABALHOS RELACIONADOS | 23 |
| 2.1 | Meta-Aprendizado | 23 |
| 2.1.1 | MtA em Processamento de Imagens e Visão Computacional . | 24 |
| 2.2 | Seleção de Algoritmos de Segmentação de Imagens | 25 |
| 3 | FUNDAMENTAÇÃO TEÓRICA | 27 |
| 3.1 | Processamento de Imagens Digitais e Visão Computacional . | 27 |
| 3.1.1 | Segmentação de Imagens | 28 |
| 3.1.1.1 | Otsu | 28 |
| 3.1.1.2 | <i>K-means</i> | 30 |
| 3.1.1.3 | <i>Support Vector Machine</i> | 31 |
| 3.1.2 | Extração de Características de Imagens | 34 |
| 3.2 | Aprendizado de Máquina | 35 |
| 3.3 | Meta-Aprendizado | 37 |
| 4 | MODELO PROPOSTO | 39 |
| 5 | EXPERIMENTOS | 41 |
| 5.1 | Meta-bases | 41 |
| 5.2 | Meta-descritores | 41 |
| 5.3 | Meta-atributo Alvo | 43 |
| 5.4 | Meta-aprendizes | 45 |
| 5.5 | Medidas de Performance | 45 |
| 6 | RESULTADOS E DISCUSSÃO | 47 |
| 6.1 | Importância dos Meta-Descritores | 50 |
| 6.2 | Predições do <i>Random Forest</i> | 53 |
| 7 | CONCLUSÃO | 55 |
| 7.1 | Trabalhos Futuros | 55 |

| | |
|--|-----------|
| REFERÊNCIAS | 57 |
| Trabalhos Publicados pelo Autor | 63 |

1 INTRODUÇÃO

A Visão Computacional (VC) estuda métodos, técnicas e equipamentos que possibilitam a construção de aplicações práticas de visão [2]. A VC tem sido utilizada para solucionar problemas em diversas áreas, por exemplo, em aplicações médicas [3, 4, 5, 6], aplicações em qualidade de alimentos [7, 8, 9, 10], sensoriamento remoto [11, 12, 13, 14], dentre outras. Uma vez que a VC é amplamente utilizada para a resolução de problemas reais, é importante realizar pesquisas que busquem avançar seu estado-da-arte e o de suas sub-áreas.

Técnicas de Processamento de Imagens, Inteligência Artificial e Reconhecimento de Padrões são geralmente utilizadas para criar sistemas de VC. Uma etapa muito importante, presente em grande parte dos sistemas de VC, consiste em identificar e isolar uma região de interesse. No campo do Processamento de Imagens, esse processo é chamado de segmentação.

A segmentação é uma das tarefas mais complexas existentes na área do Processamento de Imagens Digitais [15], além de ser um dos problemas mais estudados nos campos de Análise de Imagens e Visão computacional [16]. Existem diversos algoritmos de segmentação de imagens, porém, para uma dada imagem, a maioria deles apresentará desempenhos diferentes. Além disso, seguindo um conceito comum no campo do Aprendizado de Máquina (AM) e embasado pelo *No free lunch theorem* [17], nenhum algoritmo de segmentação é a melhor escolha para todos os tipos de imagens. A melhor solução é selecionar diferentes algoritmos para diferentes tipos de imagens, porém esta é uma tarefa difícil [18].

Nos últimos anos, diversas abordagens de segmentação de imagens foram propostas. Uma das maneiras de descobrir quais algoritmos de segmentação são adequados para uma imagem (ou para um tipo específico de imagens) é realizando a segmentação por todos os algoritmos em questão e avaliando os resultados, tal qual feito em [16]. No entanto, nem sempre é uma solução viável testar e avaliar todos os algoritmos de segmentação para uma dada imagem.

Uma alternativa é recomendar algoritmos de segmentação com bom desempenho para um problema específico através um conjunto de descritores que o represente, aliados a métodos supervisionados de classificação [18, 19]. Uma vez que os descritores (ou características) de uma imagem fornecem informações úteis para a classificação automática da mesma [20], esse processo se torna possível.

Uma abordagem recente para resolver o problema da seleção de algoritmos é o Meta-Aprendizado (MtA) [21]. A ideia consiste em aplicar o conhecimento adquirido pre-

viamente na resolução de problemas de classificação para, dada uma nova base de dados, recomendar técnicas que foram aplicadas com sucesso em problemas similares. O conhecimento é representado por um meta-modelo que, no cenário de segmentação de imagens, é responsável por mapear as características da base de dados (meta-características), relacionando cada imagem com a performance de algoritmos de segmentação que foram nela aplicados. O MtA tem sido aplicado em diferentes contextos, como, por exemplo, para selecionar [22], ranquear [23] ou prever [24] a performance de algoritmos de Aprendizado de Máquina no intuito de utilizá-los em novas bases de dados.

O MtA também tem sido aplicado na área do Processamento de Imagens Digitais e na Visão Computacional, por exemplo, para selecionar os melhores parâmetros para o algoritmo de segmentação *Watershed* [25], na detecção e localização de objetos [26] e em problemas envolvendo busca por imagens similares [27].

Neste trabalho, o MtA foi utilizado para lidar com o problema de recomendar algoritmos de segmentação. Isto é, para uma dada imagem, diversos meta-atributos são extraídos e, com a informação fornecida por eles, algoritmos adequados para segmentar a imagem em questão são recomendados.

É importante destacar que, diferente do trabalho apresentado em [19], a abordagem proposta neste trabalho levou em consideração informações relacionadas à cor, tanto nos processos de segmentação das imagens quanto nos processos de classificação supervisionada. Além disso, as meta-bases (bases de dados de Meta-Aprendizado) foram construídas utilizando imagens reais. Em [19], uma abordagem de aprendizado supervisionado foi aplicada na seleção de algoritmos de segmentação, porém as imagens utilizadas nos experimentos eram sintéticas, em tons de cinza e compostas por formas geométricas, além de não ter sido utilizado o conceito de MtA na construção do modelo supervisionado.

1.1 Objetivos

Esta Seção formaliza os objetivos do trabalho como descrito a seguir.

1.1.1 Objetivo principal

Uma vez que os descritores de uma imagem fornecem informações úteis para a classificação automática da mesma e o MtA tem sido usado recentemente para resolver o problema da seleção de algoritmos, o objetivo deste trabalho é utilizar Meta-Aprendizado e descritores de imagens para recomendar algoritmos de segmentação, utilizando imagens reais, coloridas e que representem problemas comuns de visão computacional.

1.1.2 Objetivos específicos

1. Verificar se é possível, utilizando o conceito de meta-aprendizado, recomendar algoritmos de segmentação com uma performance adequada;
2. Realizar experimentos para concluir qual algoritmo de AM tem o melhor desempenho como meta-recomendador;
3. Investigar a relevância dos descritores de imagens para cada base de dados.

1.2 Organização do Trabalho

Este trabalho está organizado conforme apresentado:

- O Capítulo 2 apresenta os trabalhos relacionados, exemplificando como soluções relacionadas a este trabalho foram propostas. Primeiramente, são apresentados trabalhos que utilizaram o conceito de Meta-Aprendizado de forma geral, seguidos por trabalhos que utilizaram Meta-Aprendizado especificamente em Processamento de Imagens e Visão Computacional. Por último, são apresentadas as abordagens disponíveis na literatura para realizar a seleção de algoritmos de segmentação de imagens.
- O Capítulo 3 apresenta os conceitos e métodos nos quais este trabalho foi baseado. Dentre eles estão a Segmentação de Imagens, Extração de Características, Aprendizado de Máquina e Meta-Aprendizado.
- O Capítulo 4 descreve a abordagem proposta neste trabalho, que vai desde a construção da meta-base até a indução e avaliação do modelo supervisionado.
- O Capítulo 5 descreve a metodologia adotada para a condução dos experimentos, incluindo a descrição das meta-bases, meta-descritores, distribuição de classes, meta-aprendizes e métricas de avaliação.
- O Capítulo 6 apresenta os resultados obtidos por meio dos experimentos e apresenta discussões sobre o desempenho da abordagem, importância dos meta-descritores e amostras problemáticas.
- O Capítulo 7 apresenta as conclusões obtidas nos resultados, com discussões sobre as limitações do trabalho realizado e possibilidades de trabalhos futuros.

2 TRABALHOS RELACIONADOS

Este capítulo está dividido em três seções. Na Seção 2.1, são apresentados trabalhos onde o MtA foi utilizado de forma geral. Nos trabalhos apresentados na Seção 2.1.1, o MtA foi aplicado na área do Processamento de Imagens Digitais e na Visão Computacional. Já na Seção 2.2, são apresentados trabalhos relacionados à seleção de algoritmos de segmentação de imagens.

2.1 Meta-Aprendizado

O conceito de Meta-Aprendizado, introduzido em [21], traz a ideia de aprender sobre o aprendizado. Esse conceito tem sido utilizado juntamente com técnicas de Mineração de Dados e Aprendizado de Máquina para resolver problemas de sugestão de algoritmos e de parâmetros. Ao aplicar diversos algoritmos de AM em diferentes problemas/bases de dados, por exemplo, é possível adquirir conhecimento e experiência (meta-conhecimento). Basicamente, o MtA consiste em utilizar esse conhecimento e experiência adquiridos para recomendar algoritmos para novos problemas/bases de dados [28].

O meta-conhecimento é representado por um meta-modelo. Imagine que diferentes algoritmos de AM aplicados na resolução de diferentes problemas obterão diferentes performances. O meta-modelo contém a relação entre a performance dos algoritmos e as características do problema, sendo assim capaz de inferir, por exemplo, o melhor algoritmo para um novo problema com base apenas em suas características. Essas características do problema/base dados também são chamadas de meta-descritores.

Em [28], o MtA foi utilizado para determinar o melhor número de *clusters* (grupos) em problemas de agrupamento de dados. Foram utilizadas métricas de qualidade de agrupamento já existentes na literatura associadas a uma nova métrica proposta: a medida de desconectividade. Essas métricas foram incorporadas em uma abordagem de MtA. Durante os experimentos, o método proposto foi comparado com outras técnicas existentes utilizando 13 cenários de dados com geometrias e tipos de agrupamentos diferentes. Em geral, a proposta obteve bons resultados e, em 2 dos 13 cenários estudados, atingiu cerca de 75% de acertos onde as outras técnicas atingiram valores em torno de 10%. Portanto, foi concluído que a proposta é promissora em estimar o melhor número de *clusters* para uma base de dados. Segundo os autores, uma das principais limitações do método proposto é o alto custo computacional.

O MtA foi usado em [29] na otimização dos parâmetros do algoritmo de classificação supervisionada *Support Vector Machine* (SVM). Dado um problema de classificação como entrada para o algoritmo, a abordagem proposta utiliza o conceito de MtA para

sugerir uma configuração inicial para os parâmetros do algoritmo SVM. A configuração inicial, baseada em problemas anteriores que possuem características similares, é então refinada por um algoritmo de otimização. Os experimentos foram realizados em uma meta-base formada por 100 problemas reais de classificação e, de acordo com quatro métricas de avaliação, a inicialização por MtA gerou resultados melhores em até 76% dos meta-exemplos se comparados à inicialização aleatória. Os autores acreditam que a performance da abordagem proposta pode ser melhorada se mais meta-exemplos forem adicionados à meta-base.

Um método para seleção periódica de algoritmos em ambientes onde os dados mudam com frequência foi proposto em [23]. O algoritmo proposto utiliza o conceito de MtA, induzindo um meta-modelo que relaciona as características extraídas de dados passados com o desempenho da predição de algoritmos de aprendizado, permitindo prever o desempenho dos algoritmos para novos dados de entrada. Três algoritmos de Aprendizado de Máquina foram utilizados como meta-aprendizes (responsáveis por induzir o meta-modelo): *Random Forest* (RF), o algoritmo de agrupamento k-Vizinhos Próximos (em inglês-Nearest Neighbors- k-NN), e um classificador *Naïve Bayes* (NB). Os resultados dos experimentos mostraram que o método proposto é capaz de aprimorar a performance geral de sistemas que utilizam AM em ambientes onde os dados mudam com frequência.

Em [30], o conceito de MtA foi usado para selecionar o melhor algoritmo de *clustering* (agrupamento) para um dado problema. Foi proposta uma nova abordagem para caracterizar problemas de agrupamento baseada na similaridade dos objetos. Foram também propostos novos métodos para realizar o ranqueamento dos algoritmos com base em sua performance. A algoritmo de agrupamento k-NN foi utilizado como meta-aprendiz nesse trabalho. Após a realização dos experimentos, observou-se que a abordagem proposta realiza com alta qualidade a tarefa de selecionar algoritmos para problemas de agrupamento.

Existem mais trabalhos que utilizaram MtA para recomendar algoritmos de AM, como em [31] e [32], e também para otimizar os parâmetros desses algoritmos [24, 33, 34].

O conceito de MtA também foi utilizado nos trabalhos apresentados na próxima seção, porém com o foco na resolução de problemas relacionados às áreas de Processamento de Imagens e Visão Computacional.

2.1.1 MtA em Processamento de Imagens e Visão Computacional

Nos últimos anos, o MtA também foi aplicado na resolução de problemas envolvendo Processamento de Imagens e Visão Computacional. Em [25], por exemplo, os autores aplicaram MtA para relacionar descritores de imagem com os resultados do algoritmo de segmentação *Watershed*. Desta maneira eles foram capazes de identificar, para uma nova imagem, qual seria o melhor conjunto de parâmetros do algoritmo *Watershed*

para segmentá-la.

Uma solução para detecção e localização de objetos foi apresentada em [26], onde o algoritmo AdaBoost foi utilizado para realizar o MtA e a seleção de descritores. Os resultados dos experimentos em três bases de dados diferentes apresentaram resultados similares aos de algoritmos estado-da-arte, porém se mostrou uma abordagem mais abrangente (capaz de resolver mais problemas).

O problema da busca por imagens similares foi discutido em [27]. Os autores utilizaram uma variação do algoritmo de otimização *Particle Swarm Optimization* (PSO) e MtA para resolver o problema de busca. A abordagem proposta apresentou resultados melhores do que quando usando apenas o algoritmo PSO tradicional.

2.2 Seleção de Algoritmos de Segmentação de Imagens

O problema de selecionar um bom algoritmo para segmentar uma imagem (ou um grupo de imagens similares) pode ser solucionado através da avaliação da segmentação, onde a imagem é segmentada por vários algoritmos e o de melhor performance é selecionado. Porém, também é possível prever se um algoritmo de segmentação será adequado para uma dada imagem antes mesmo de segmentá-la. Isso pode ser feito utilizando descritores da imagem e algoritmos de classificação supervisionados.

Em [16], foi proposto um método para avaliar algoritmos de segmentação de uma perspectiva de alto nível, isto é, se a segmentação foi capaz de realizar seu papel na aplicação ou não, independente da acurácia da segmentação em si. Apesar de o método requerer que a imagem seja segmentada por todos os algoritmos a serem avaliados, os resultados foram promissores, sendo útil para decidir quais métodos de segmentação são ou não são adequados para uma dada imagem.

Uma abordagem de classificação supervisionada para selecionar um algoritmo de segmentação foi proposta em [19]. A proposta apresentou bons resultados, porém os experimentos foram realizados utilizando apenas imagens sintéticas de formas geométricas simples em tons de cinza e levando em conta apenas algoritmos de segmentação por *thresholding* (mais simples). Os problemas recentes em aplicações de segmentação de imagens frequentemente envolvem imagens coloridas e segmentações complexas, sendo interessante realizar pesquisas mais atuais sobre o assunto.

Em [18], foi proposto um *framework* para realizar a segmentação de imagens intracelulares. O *framework* proposto foi capaz de selecionar o melhor algoritmo para segmentar as imagens intracelulares. Essa seleção foi feita utilizando medidas de similaridade entre regiões segmentadas por especialistas e regiões automaticamente segmentadas pelos algoritmos. Apesar do *framework* ser voltado para resolver um problema específico, os resultados mostraram que o mesmo é capaz de selecionar um algoritmo adequado para

segmentar uma nova região que possua características similares às previamente segmentadas por um especialista.

Levando em conta que é possível relacionar descritores de uma imagem com algoritmos adequados para a sua segmentação e que o MtA tem sido usado em trabalhos recentes para realizar a seleção de algoritmos, a ideia de utilizar MtA para recomendar algoritmos de segmentação de imagens parece promissora. No levantamento bibliográfico realizado, até o momento, não foi encontrado nenhum trabalho que utilizasse o conceito de MtA para recomendar algoritmos de segmentação de imagens.

3 FUNDAMENTAÇÃO TEÓRICA

Este Capítulo apresenta os conceitos e métodos nos quais esta dissertação baseia-se. Os conceitos básicos da área de Processamento de Imagens serão abordados na Seção 3.1. Na mesma seção, as sub-áreas do Processamento de Imagens que possuem mais relação com este trabalho são aprofundadas, sendo elas a Segmentação e Extração de Características de Imagens. Com as características extraídas das imagens e com o auxílio de algoritmos de AM, é possível realizar a classificação automática das mesmas. Os algoritmos de AM utilizados neste trabalho são descritos na Seção 3.2. O Meta-aprendizado, que é responsável por unir os conceitos anteriores para criar um método capaz de recomendar algoritmos de segmentação, é descrito na Seção 3.3.

3.1 Processamento de Imagens Digitais e Visão Computacional

Uma imagem digital é composta de um número finito de elementos, cada um com localização e valor específicos. Esses elementos são chamados de *pixels* [35]. É possível abstrair uma imagem digital como uma matriz de valores numéricos, onde cada posição da matriz é um pixel. O valor de cada pixel é proporcional ao brilho daquele ponto na cena [36].

Após a aquisição de uma imagem por um dispositivo próprio (câmera, *scanner*, ultra-som, etc), ela pode ser processada. Essa manipulação (ou processamento) pode, por exemplo, envolver o rearranjo ou a mudança dos tons dos *pixels* da imagem. A área do Processamento de Imagens inclui tópicos como atenuação de ruídos, restauração, realce, segmentação, dentre outros [37].

A Visão Computacional estuda métodos, técnicas e *hardwares* que possibilitam a construção de Sistemas de Visão Computacional para aplicações práticas [2]. Esses métodos e técnicas são, em boa parte, de Processamento de Imagens e Inteligência Artificial.

Segundo [37], três das partes tradicionais em um Sistema de Visão Computacional são: Segmentação (*a*), Extração de Características (*b*) e Classificação/Reconhecimento da imagem (*c*). Essas etapas estão altamente relacionadas ao trabalho proposto nessa dissertação, cujo objetivo é utilizar características da imagem (*b*) para recomendar (*c*) algoritmos de segmentação (*a*). Os principais conceitos sobre Segmentação de Imagens e Extração de Características são apresentados nesta seção, enquanto os conceitos e algoritmos para Classificação de Imagens (utilizando Aprendizado de Máquina) são descritos na Seção 3.2.

3.1.1 Segmentação de Imagens

A segmentação de uma imagem consiste em identificar e isolar uma região de interesse. Também pode ser definida como a ação de subdividir uma imagem em regiões ou objetos que a compõe [35]. A segmentação de imagens não triviais é uma das tarefas mais difíceis na área de Processamento de Imagens [15, 35], além de ser um dos problemas mais estudados nos campos de Análise de Imagens e Visão Computacional [16].

Existem diversos tipos de algoritmos de segmentação, podendo ser baseados em limiarização (*thresholding*), crescimento de regiões, detecção de bordas, agrupamento de *pixels* (*clustering*), classificação supervisionada, dentre outros [38, 39, 40, 1].

Neste trabalho, foram utilizados três segmentadores conhecidos e amplamente utilizados, cada um representando um dos tipos de algoritmo. São eles: o **Otsu** (representando os algoritmos de *thresholding*), o **K-means** (representando os algoritmos de *clustering*) e a Máquina de Vetor de Suporte (em inglês *Support Vector Machine* - **SVM**) (representando os algoritmos de classificação supervisionada). Os três segmentadores utilizados são descritos a seguir:

3.1.1.1 Otsu

A limiarização (*thresholding*) é popular em aplicações de segmentação de imagens, por ser intuitiva, de simples implementação e de baixa complexidade computacional [35]. A limiarização consiste em encontrar um valor de limiar (*threshold*) que separe os *pixels* da imagem em duas classes: os que possuem nível de cinza abaixo do limiar e os que possuem nível de cinza acima do limiar [37].

Na Figura 3.1 é possível observar um exemplo de segmentação por limiarização. A Figura 3.1a é a imagem original. A Figura 3.1b é o histograma da imagem original: um gráfico cartesiano que fornece, para cada nível de cinza, o percentual de *pixels* correspondentes na imagem. Na Figura 3.1b, o valor de *threshold* escolhido (127) está marcado por uma linha. Por último está a Figura 3.1c, que é a imagem resultante do processo de segmentação por limiarização.

Existem diversos algoritmos que se propõe a encontrar um valor de *threshold* ideal para uma imagem, podendo ser baseados no formato do histograma, variância, entropia, dentre outros [41].

O método de Otsu [42], por ser um dos mais precisos e populares métodos de segmentação de imagens [43], foi escolhido para representar os algoritmos de *thresholding*. Ele é utilizado para encontrar de forma automática, para uma imagem em tons de cinza, um valor de *threshold* que maximize a variância entre as classes. A ideia básica é que as classes devem ser distintas em relação aos valores de intensidade de seus *pixels* e, conseqüentemente, o melhor valor de limiar seria o que oferece a melhor separação entre

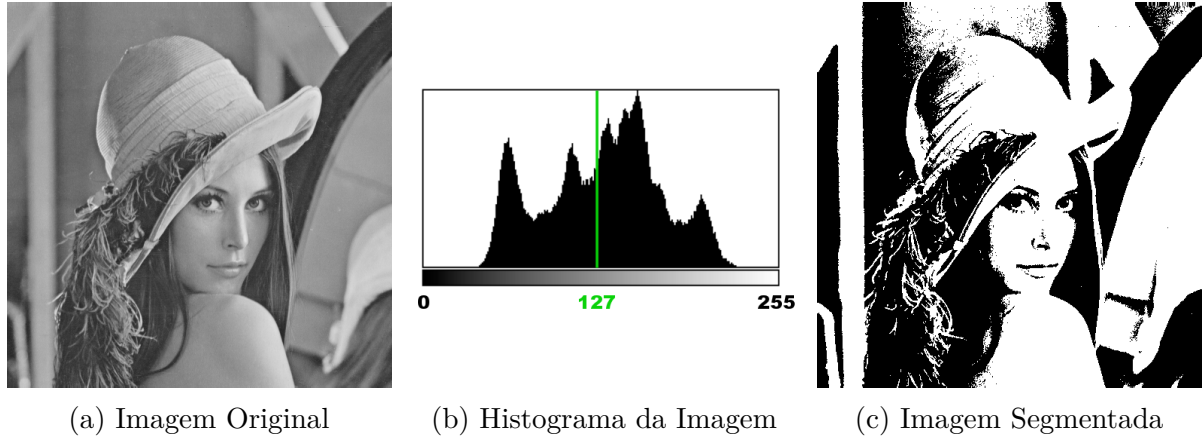


Figura 3.1 – Exemplo de segmentação por limiarização, com valor de limiar (*threshold*) 127

as classes em termos de valores de intensidade [35].

Para entender melhor o método de Otsu, considere uma imagem $I(x, y)$ e seu histograma, com tons de cinza variando de 0 a $L - 1$, onde L é o número de tons de cinza distintos possíveis na imagem (esse valor normalmente é 256, com os tons variando de 0 a 255). Sendo n o número total de *pixels* na imagem e n_i o número de *pixels* com tom de cinza i , a probabilidade do tom de cinza i ocorrer é definida por

$$p_i = \frac{n_i}{n} . \quad (3.1)$$

Como dito anteriormente, um valor de *threshold* t tem como objetivo dividir (segmentar) a imagem em duas classes, C_0 e C_1 . A classe C_0 é composta por *pixels* com tons de cinza variando de 0 até t , enquanto a classe C_1 é composta por *pixels* com tons de cinza variando de $t + 1$ até $L - 1$. As probabilidades acumulativas das classes C_0 e C_1 são representadas respectivamente por $P_0(t)$ e $P_1(t)$, sendo definidas pelas Equações (3.2) e (3.3):

$$P_0(t) = \sum_{i=0}^t p_i , \quad (3.2)$$

$$P_1(t) = 1 - P_0(t) . \quad (3.3)$$

Já os valores do tom de cinza médio das classes C_0 e C_1 são representados respectivamente por $M_0(t)$ e $M_1(t)$, sendo definidos pelas Equações (3.4) e (3.5):

$$M_0(t) = \sum_{i=0}^t i \cdot \frac{p_i}{P_0(t)} , \quad (3.4)$$

$$M_1(t) = \sum_{i=t+1}^{L-1} i \cdot \frac{p_i}{P_1(t)}. \quad (3.5)$$

O objetivo do método de Otsu é encontrar um valor de *threshold* que maximize a variância entre as classes. Para isso, todos os valores de *threshold* possíveis no histograma de intensidade da imagem são testados e o que gera o maior valor de variância entre as classes é selecionado [35]. O valor de variância entre as classes C_0 e C_1 , separadas por um valor de *threshold* t , é dado por $V(t)$, onde

$$V(t) = P_0(t) \cdot (M_0(t))^2 + P_1(t) \cdot (M_1(t))^2. \quad (3.6)$$

Ao calcular $V(t)$ para todos os tons de cinza possíveis em uma imagem, o tom de cinza t que retornar o maior valor em $V(t)$ é o *threshold* ótimo segundo o método de Otsu.

3.1.1.2 *K-means*

O agrupamento dinâmico de dados (*clustering*) consiste na criação de grupos de amostras com base na similaridade de suas características, utilizando alguma métrica de distância para agrupar dados semelhantes. O *K-means* foi escolhido para representar os algoritmos de *clustering* nos experimentos realizados, uma vez que é um dos algoritmos mais simples e populares que resolvem o problema de agrupamento dinâmico de dados [44, 45, 46].

Esse método pode ser aplicado em diferentes áreas, incluindo a segmentação de imagens através do agrupamento de *pixels*. O *K-means* agrupa os n *pixels* da imagem em k grupos (*clusters*) através de alguma medida de distância [46], podendo ser aplicado tanto em imagens em tons de cinza quanto em imagens coloridas.

Na Figura 3.2 é possível observar dois exemplos de segmentação por *clustering* utilizando o algoritmo *K-means*. A Figura 3.2a é a imagem original, a Figura 3.2b é a imagem resultante do processo de separação (segmentação) em 3 grupos ($k = 3$) e a Figura 3.2c é a imagem resultante do processo de separação (segmentação) em 5 grupos ($k = 5$). Cada pixel foi rotulado com a cor média do grupo ao qual pertence (o centroide do grupo).

O passo a passo para realizar a segmentação de uma imagem em k grupos pelo *K-means* pode ser observado na Figura 3.3.

Existem outros métodos na literatura para realizar a escolha dos centroides iniciais, porém a solução clássica é a escolha aleatória. Existem também diversas medidas de distância podem ser utilizadas no algoritmo, sendo a Euclidiana a mais comum. O critério



(a) Imagem Original

(b) Segmentação com $k = 3$ (c) Segmentação com $k = 5$ Figura 3.2 – Exemplos de segmentação por *clustering* utilizando o algoritmo *K-means***Algoritmo 1: *K-means*****Entrada:** Número k de grupos e vetor de dados de entrada**Saída:** Valores dos k centros e vetor com o rótulo atribuído a cada dado de entrada

- 1 Inicializa os k centros de grupos (centroides) aleatoriamente
- 2 **repita**
- 3 Calcula a distância entre cada *pixel* e cada centroide
- 4 Associa cada *pixel* ao grupo cujo centroide está mais próximo, tendo como base as distâncias calculadas na linha 3
- 5 Recalcula os centroides, atribuindo a cada um deles o valor da média dos *pixels* que estão em seu grupo
- 6 **até** Critério de convergência ser atingido;
- 7 **retorna** Valores dos k centros e vetor com o rótulo atribuído a cada dado de entrada

Figura 3.3 – Algoritmo K-means

de convergência para o algoritmo *K-means* normalmente é uma variação mínima dos centros entre as iterações ou o número total de iterações.

Ao final do processo, a imagem está agrupada (segmentada) e rotulada em k classes. Desta maneira, é possível, por exemplo, remover os *pixels* das classes indesejadas, mantendo apenas as Regiões de Interesse (ROIs).

3.1.1.3 *Support Vector Machine*

Os algoritmos de AM para classificação supervisionada produzem hipóteses gerais a partir de instâncias previamente fornecidas [47], ou seja, a partir de alguns exemplos de amostras cuja classe é conhecida, o classificador pode prever a classe de amostras futuras.

Recentemente, abordagens de AM como Redes Neurais e SVMs tem sido utilizadas

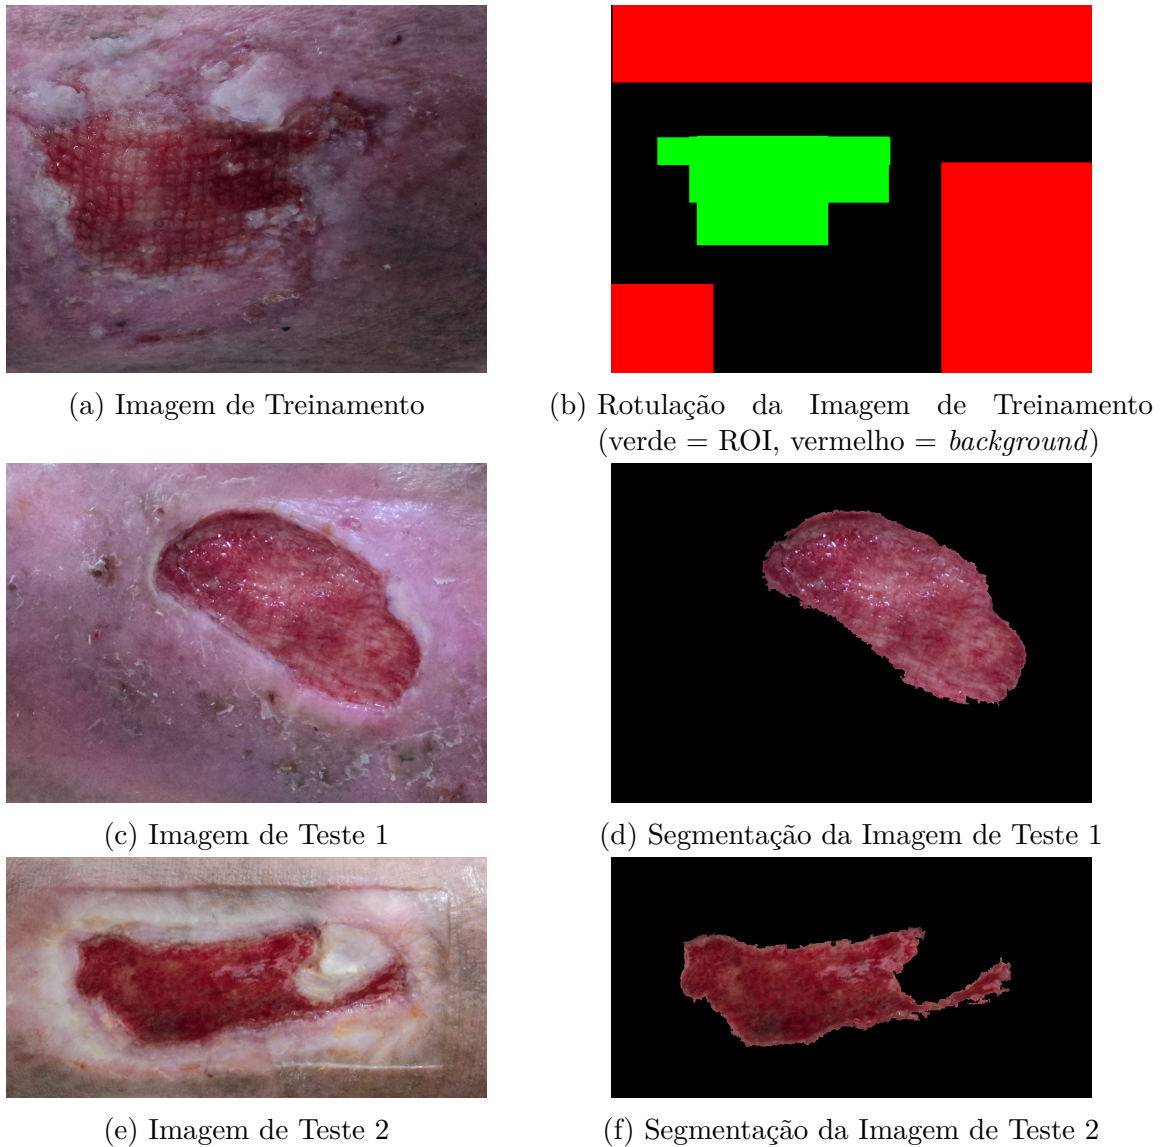


Figura 3.4 – Exemplos de segmentação por classificação supervisionada, realizada nos experimentos deste trabalho

com sucesso para segmentar imagens [1], uma vez que a segmentação de imagens pode ser visto como um problema de classificação de *pixels* [48]. A segmentação de imagens através de classificação supervisionada é útil, por exemplo, quando se pretende segmentar um conjunto grande de imagens similares, compensando o esforço necessário para treinar o classificador.

Na Figura 3.4, é possível observar exemplos de segmentação por classificação supervisionada.

A Figura 3.4a pertence a uma das bases de dados utilizadas neste trabalho (descrita na Seção 5.1), composta por imagens médicas e tendo como ROI as áreas de lesão. Os *pixels* da Figura 3.4a foram utilizados como exemplos para treinar o classificador, de acordo com o rótulo associado a cada *pixel* na Figura 3.4b (pixel com rótulo verde =

ROI, pixel com rótulo vermelho = *background*). O algoritmo de AM é responsável por encontrar as relações entre as classes (ROI ou *background*) e as características dos *pixels* (que podem ser seus valores de RGB, por exemplo). Apenas *pixels* não duvidosos foram rotulados pelo especialista e, a partir desses exemplos, o classificador é treinado. Com o modelo (classificador) pronto, é possível prever a qual classe pertence cada *pixel* de uma nova imagem (segmentar), desde que essa imagem seja similar aos exemplos utilizados no processo de treinamento. É possível observar nas Figuras 3.4d e 3.4f, o resultado da segmentação por classificação supervisionada das Figuras 3.4c e 3.4e, onde apenas os *pixels* classificados como ROI foram mantidos.

O SVM é um método de aprendizado supervisionado capaz de realizar classificação e regressão [49]. O algoritmo SVM foi escolhido para representar a segmentação por classificação supervisionada neste trabalho, uma vez que apresenta alta acurácia, alta velocidade computacional, possui grande habilidade de generalização e é um método robusto. Além disso, o SVM possui vantagens em lidar com problemas de classificação com poucas amostras de treinamento, não lineares e de alta dimensionalidade, fazendo com que seja um método adequado para a segmentação de imagens [48].

O objetivo do SVM é encontrar um hiper-plano que maximize a distância mínima entre cada amostra [1]. Através do princípio de minimização de risco estrutural, o algoritmo consegue superar o conflito entre *over-fitting* e *under-fitting* (ajuste em excesso ou em falta de um classificador em uma base de treinamento).

Na Figura 3.5, é possível observar um exemplo do melhor hiper-plano (o que maximiza a distância mínima entre as amostras) com seus vetores de suporte e um hiper-plano não ideal, para dados genéricos.

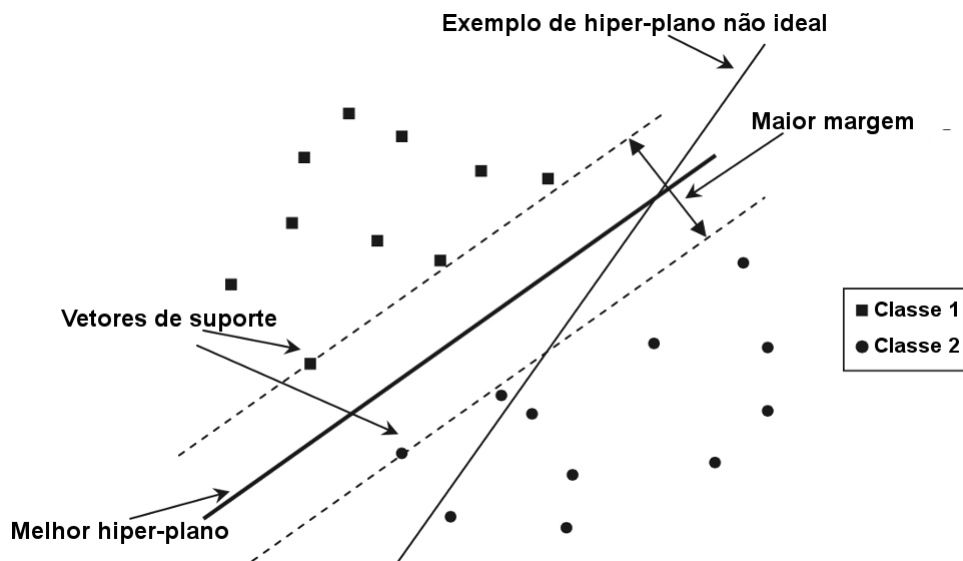


Figura 3.5 – Exemplo de hiperplano detectado via algoritmo SVM para um problema de separação linear [1]

No caso da Figura 3.5 foi utilizado um núcleo (*kernel*) linear. Porém, diversos tipos de núcleos podem ser utilizados com o algoritmo SVM, dentre eles o polinomial, o de base radial (*Radial Basis Function* - RBF), perceptron multi-camadas (*Multilayer Perceptron* - MLP), entre outros.

3.1.2 Extração de Características de Imagens

As características ou descritores são informações quantitativas que podem ser obtidas ao analisar as imagens, sendo úteis para realizar classificação automática e reconhecimento de padrões [20, 37]. Existem diversos tipos de descritores que podem caracterizar uma imagem ou os objetos presentes nela, como a cor, forma, textura, dimensão, entre outros [37].

Neste trabalho, 44 características das imagens foram utilizadas como meta-descritores. Elas podem ser divididas em seis grupos: Cor, Domínio da Frequência, Histograma de Intensidade, Matriz de Co-ocorrência, Contraste e Qualidade da Imagem. Os principais conceitos envolvendo cada um desses esses grupos de características são:

- **Características da Cor:** As características da cor fornecem informações sobre o aspecto da imagem [37], sendo um dos tipos mais dominantes e perceptíveis de descritores. Diversos pesquisadores tem utilizado as características da cor para segmentar [1] e para classificar imagens [50]. Os momentos estatísticos de diferentes canais em diferentes espaços de cor podem oferecer as informações necessárias para realizar a classificação da imagem [50]. Neste trabalho, foram utilizados os valores da média, variância e desvio padrão dos espaços de cor RGB e HSV ¹, totalizando 18 descritores.
- **Características do Domínio da Frequência:** A Transformada Rápida de Fourier (*Fast Fourier Transform* - FFT) pode ser utilizada para alcançar o Domínio da Frequência, tornando possível descrever padrões globais de textura em uma imagem [35]. Segundo [36], é possível obter a descrição da textura da imagem com um conjunto de medidas estatísticas extraídas da FFT. As características do Domínio da Frequência utilizadas neste trabalho foram as seguintes medidas estatísticas: Energia, Entropia, Homogeneidade e Inércia, todas extraídas da FFT.
- **Características do Histograma da Intensidade:** O histograma de uma imagem consiste em um gráfico cartesiano no qual o eixo horizontal reflete os valores das tonalidades de cinza que a imagem pode assumir, enquanto o eixo vertical apresenta a frequência na qual essas tonalidades ocorrem. Uma das maneiras mais simples de descrever uma imagem é através de medidas estatísticas extraídas do

¹ RGB é a sigla para o espaço de cor *Red, Green and Blue* (Vermelho, Verde e Azul), enquanto HSV é a sigla para o espaço de cor *Hue, Saturation and Value* (Matiz, Saturação e Valor/Brilho).

seu histograma de intensidade [35]. Neste trabalho, foram utilizados descritores do histograma difundidos na literatura como os momentos estatísticos (média, desvio padrão, obliquidade e curtose) e outras métricas propostas em [20].

- **Características da Matriz de Co-ocorrência:** A Matriz de Co-ocorrência em nível de cinza (ou intensidade) é um dos métodos mais utilizados para descrever a textura de uma imagem [37]. A ideia é representar a frequência com que dois *pixels* em nível de cinza, separados por distância e ângulo pré-definidos, ocorrem em uma imagem. Desta maneira, o tamanho da Matriz de Co-ocorrência não varia de acordo com o tamanho da imagem e sim de acordo com o número de tons de cinza da mesma [37]. Como pode ser visto em [35] e em [37], existem diversos descritores úteis para caracterizar o conteúdo da Matriz de Co-ocorrência. Neste trabalho, foram utilizadas as seguintes descritores: Entropia, Homogeneidade, Inércia, Correlação e Energia.
- **Características de Contraste:** Duas características de contraste foram utilizadas neste trabalho: a Entropia da Intensidade e o Fator de Contraste Global (*Global Contrast Factor* - GCF). A Entropia da Intensidade também é calculada através do histograma de intensidade, porém foi colocada nesse grupo por ser uma métrica comum de contraste [51]. O GCF, proposto em [52], tem como objetivo representar da maneira mais precisa possível a percepção humana do contraste.
- **Características de Qualidade da Imagem:** Os algoritmos de Avaliação de Qualidade da Imagem (*Image Quality Assessment* - IQA) tem como objetivo avaliar a qualidade de uma imagem de maneira automática e de acordo com a percepção visual humana de qualidade [53]. Dois métodos de IQA foram utilizados como descritores na abordagem proposta: a Medida de Naturalidade Estatística (*Statistical Naturalness Measure* - SNM) e a Medida de Melhoria (*Measure of Enhancement* - EME) [53].

3.2 Aprendizado de Máquina

Um problema de classificação consiste em relacionar um vetor de características de uma amostra com a classe à qual ela pertence. Os algoritmos de Aprendizado de Máquina são capazes de inferir essas relações através de exemplos fornecidos previamente, permitindo atribuir a um exemplo desconhecido uma entre várias classes conhecidas [54].

Neste trabalho, foram efetuados experimentos com sete métodos distintos de Aprendizado de Máquina. A seguir, são descritos os principais conceitos envolvendo o funcionamento de cada um dos algoritmos utilizados.

- **Regressão Logística (LogReg):** A Regressão Logística é um classificador linear probabilístico. Nesse classificador, os dados de treinamento são projetados em um

conjunto de hiper-planos, cada um correspondendo a uma classe. A distância de uma nova amostra para um hiper-plano reflete a probabilidade de que ela pertença à classe corresponde do hiper-plano em questão [55, 56]

- **Árvore de Decisão J48 (J48):** Os algoritmos de Árvores de Decisão são tradicionais e poderosos métodos de AM [54]. Como dito em [57], são algoritmos populares e de fácil entendimento, uma vez que encontrar a resposta seguindo os ramos de uma árvore é mais intuitivo do que, por exemplo, em uma rede neural. O algoritmo J48 é uma versão modificada do algoritmo de construção de árvores de decisão c4.5 [58]. Essa árvore, similar a um grafo, funciona como um sistema de suporte à decisão onde cada nó é um teste em um atributo, cada ramo é a saída de um teste e cada folha é o rótulo de uma classe (resultado) [59]. O algoritmo constrói a árvore explorando o conceito de ganho de informação de cada atributo, com a ideia de decompor um problema complexo em vários sub-problemas mais simples recursivamente, até satisfazer um critério de parada [57].
- **Classificador *Naïve Bayes* (NB):** Os classificadores *Naïve Bayes* são uma família de classificadores probabilísticos simples, capazes de lidar com grandes bases de dados e frequentemente utilizados em *benchmarks* como comparação para novos classificadores [60, 61]. O NB tem sido amplamente estudado desde os anos 50 e, em alguns domínios, sua performance é comparável a de algoritmos de árvores de decisão e redes neurais [60].
- **Algoritmo de Agrupamento k-Nearest Neighbor (k-NN):** O algoritmo k-NN é o mais simples dos métodos baseados em instância (*instance-based*). Esse algoritmo assume que cada amostra é um ponto no espaço de n -dimensões (onde n é o número de atributos) [60]. Dada uma nova amostra, seus k vizinhos são calculados através de métricas de distância (normalmente é utilizada a Distância Euclidiana). Uma vez encontrados os vizinhos, a média deles é atribuída como valor predito para a amostra de entrada.
- ***Random Forest* (RF):** O algoritmo RF, introduzido em [62], combina Árvores de Decisão em um conjunto. Essas árvores, que devem ser construídas de maneira independente e sem poda, irão classificar as amostras através de um processo de votação. Também é importante notar que cada árvore utiliza uma parte aleatória das amostras para treinamento, aumentando sua capacidade de generalização. O número de árvores e o número de atributos em cada nó são hiper-parâmetros definidos pelo usuário.
- **Redes Neurais Utilizando o Modelo de Média (avNNet):** As Redes Neurais são métodos de AM com inspiração biológica, robustos em prever valores reais e discretos [60]. Em [63], foi proposta o método avNNet, que utiliza as Redes Neurais

de maneira similar a que o algoritmo RF utiliza as Árvores de Decisão. Diferentes Redes Neurais do mesmo modelo são ajustadas com diferentes valores iniciais (as amostras de treinamento podem ou não ser as mesmas). Todas as redes treinadas são utilizadas na predição é calculada a média dos resultados para gerar a saída.

- **Support Vector Machine (SVM):** O SVM, que neste trabalho também foi utilizado como segmentador e descrito na Seção 3.1.1, é um método de classificação introduzido em [64]. O SVM pode ser utilizado com diferentes núcleos (*kernels*) e é popular no meio científico por apresentar alta acurácia, habilidade de lidar com problemas de várias dimensões e flexibilidade em modelar diversos tipos de dados [65, 57].

3.3 Meta-Aprendizado

O conceito de Meta-Aprendizado, introduzido em [21], traz a ideia de aprender sobre o aprendizado. Enquanto um modelo de AM comum é construído através do conhecimento adquirido de uma tarefa específica, um modelo de MtA (meta-modelo) é baseado na experiência adquirida pelo acúmulo de diversas aplicações de um sistema de aprendizagem [66]. Essa experiência (ou conhecimento), fruto de vários outros processos de aprendizagem, é chamada de **meta-conhecimento**.

O MtA tem sido amplamente utilizado juntamente com técnicas de Mineração de Dados e AM para resolver problemas de sugestão de algoritmos e de parâmetros. Ao aplicar diversos algoritmos de AM em diferentes problemas/bases de dados, por exemplo, é possível adquirir meta-conhecimento, que por sua vez permite recomendar algoritmos (e/ou seus parâmetros) para novos problemas/bases de dados [28].

Imagine que diferentes algoritmos de AM aplicados na resolução de diferentes problemas obterão diferentes performances. A performance dos algoritmos (**valores dos meta-atributos alvo**) e as características do problema (**meta-descritores**) formam a **meta-base**. O **meta-aprendiz**, que normalmente é um algoritmo de AM, é responsável por construir o meta-modelo, isto é, relacionar os meta-descritores com os valores dos meta-atributos alvo. O **meta-modelo** é o resultado final, estando pronto para inferir, por exemplo, o melhor algoritmo para um novo problema com base apenas em suas características. No Capítulo 4 é possível observar como a abordagem proposta se encaixa no conceito de MtA.

4 MODELO PROPOSTO

Este trabalho foi motivado por uma necessidade da Visão Computacional: selecionar um algoritmo de segmentação adequado para uma imagem ou para um grupo de imagens similares. Sabendo que o conceito de MtA tem sido utilizado em trabalhos recentes para lidar com o problema de seleção de algoritmos na área de AM, surgiu a ideia de importar esse conceito para resolver o problema da seleção de algoritmos de segmentação de imagens.

Neste trabalho, foi proposto o uso de MtA para construir um *framework* capaz de realizar essa recomendação de segmentadores. O *framework* proposto e o encaixe do problema no fluxo do MtA são ilustrados na Figura 4.1.

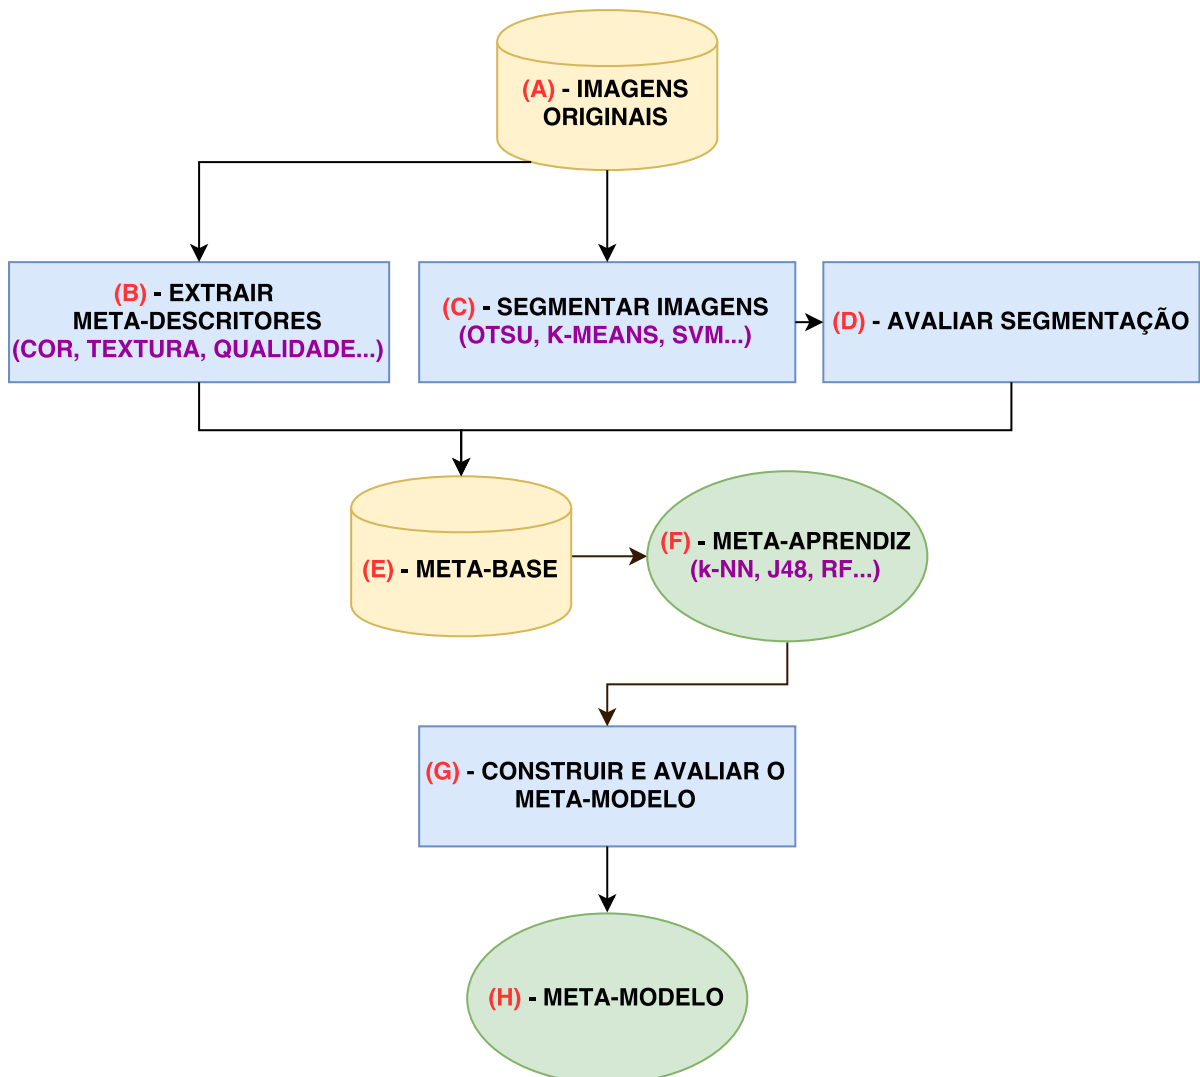


Figura 4.1 – Visão geral do modelo proposto

O diagrama começa com as imagens originais que serão usadas para treinar e testar o modelo **(A)**. No aprendizado tradicional, essa etapa é composta por diversos exemplos de um problema, enquanto no MtA é composta por diversos problemas/bases de dados (meta-exemplos). Uma vez que a segmentação é um problema de classificação de *pixels*, cada imagem passa a ser um problema/base de dados para o *framework*.

A construção da meta-base **(E)** se dá pela união de três etapas: a extração de meta-descritores **(B)**, a segmentação das imagens (por todos os algoritmos que serão considerados pelo *framework*) **(C)** e a definição dos valores dos meta-atributos alvo ao avaliar a segmentação **(D)**.

Relações similares às apresentadas para a base de dados ocorrem na construção da meta-base: No aprendizado tradicional são extraídas características de exemplos de um problema, enquanto no MtA são extraídas características dos problemas/bases de dados em si. Portanto, os meta-descritores desta proposta são características das imagens. Em uma abordagem de seleção de algoritmos baseada em MtA, cada meta-exemplo (ou seja, cada problema) é composto por suas características (meta-descritores) e pelo desempenho dos algoritmos de classificação em solucioná-lo (valores dos meta-atributos alvo). Neste caso, os algoritmos de classificação são os segmentadores e o desempenho é o resultado da avaliação da segmentação.

Uma vez obtida a meta-base **(E)**, é necessário escolher um meta-aprendiz **(F)**. O meta-aprendiz é responsável por relacionar os meta-descritores com os valores dos meta-atributos alvo, isto é, relacionar as características de imagem com o desempenho dos algoritmos de segmentação. Normalmente, um algoritmo de AM é utilizado como meta-aprendiz.

Com a meta-base pronta e o meta-aprendiz selecionado, é possível realizar a indução e avaliação **(G)** do meta-modelo **(H)** que, quando construído, está pronto para prever quais algoritmos de segmentação são adequados ou inadequados para uma nova imagem.

5 EXPERIMENTOS

Com o intuito de avaliar o desempenho da abordagem proposta, foram conduzidos experimentos com diferentes algoritmos e bases de imagens. Este capítulo apresenta uma descrição detalhada da configuração dos experimentos, incluindo todas as meta-bases, algoritmos e métodos de avaliação utilizados.

5.1 Meta-bases

Quatro meta-bases com diferentes níveis de complexidade foram utilizadas nos experimentos. A primeira (**frango**), apresentada em [7], consiste em imagens de peito de frango. A Região de Interesse, ou *Region of Interest* (ROI), dessa base de dados é a amostra de frango em si com o fundo (*background*) removido, sendo um problema de segmentação simples. A segunda base de dados, **ferida**, é composta por imagens médicas onde a ROI é uma área de ferida [4], sendo um problema de segmentação de dificuldade média. A terceira base, **nuvem**, é a mais complexa. Ela consiste em imagens de satélite onde as ROI são as nuvens ¹ [67]. Também, foram realizados experimentos com uma quarta meta-base, chamada de **completa**. Ela é formada pela junção de todas as bases de dados anteriores. Todas as imagens estavam no formato *Portable Network Graphics* (PNG) e exemplos de cada meta-base juntamente com a ROI segmentada pode ser visto na Figura 5.1.

É importante notar que as meta-bases utilizadas representam diferentes problemas do mundo real. As principais diferenças entre as meta-bases estão relacionadas à ROI (tamanho, cor e contraste com o *background*). Outro fato que motivou a seleção desses cenários de imagens foram as recentes pesquisas nas áreas de segmentação de imagens em aplicações médicas (**ferida**) [3, 4, 5, 6], qualidade de alimentos (**frango**) [7, 8, 9, 10] e análise de imagens aéreas ou de satélite (**nuvem**) [11, 12, 13, 14].

Desta maneira, as bases de dados foram escolhidas para representar problemas diversos de segmentação. Também é importante notar que diferentes algoritmos de segmentação foram utilizados nas aplicações citadas, motivando ainda mais a proposta deste trabalho de recomendar algoritmos de segmentação para uma dada imagem.

5.2 Meta-descritores

Um dos pontos principais e cruciais no MtA é a representação do meta-conhecimento, que é feita relacionando os meta-descritores com o valores dos meta-atributos alvo. Em

¹ As imagens do *Landsat 8* estão disponíveis gratuitamente no repositório da *Amazon S3*. Foram selecionadas apenas imagens com nuvens para os experimentos deste trabalho

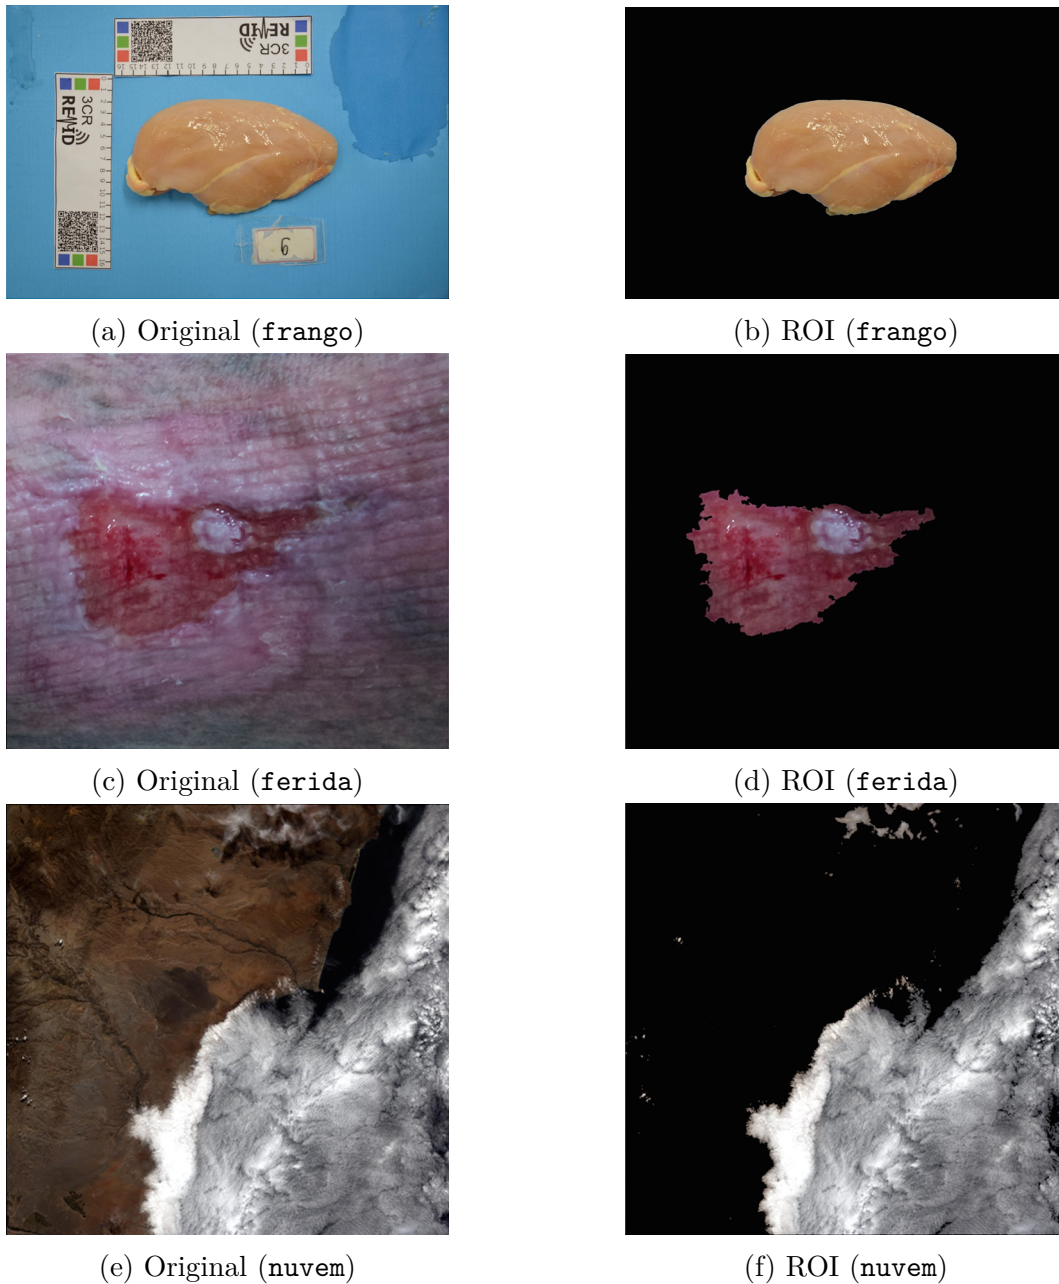


Figura 5.1 – Exemplos de segmentação adequada para cada meta-base: frango, ferida e nuvem

uma meta-base, cada problema/base de dados é representado por um vetor de características, chamadas de meta-descritores (*meta-features* em inglês). De acordo com [21], os meta-descritores devem cumprir alguns requisitos como possuir um alto poder de discriminação (capacidade de separar as classes) e a extração dos mesmos ser de baixa complexidade computacional.

Diferente do aprendizado tradicional, onde as características de exemplos (amostras) de um problema são relacionadas com as possíveis classes, no MtA são extraídas características do problema/base de dados em si e estas são relacionadas com o desempenho dos algoritmos de classificação. Na abordagem proposta, a segmentação foi assimilada

como um problema de classificação de *pixels*, ou seja, cada imagem é um problema/base de dados. Portanto, os meta-descritores utilizados são características da imagem.

Para uma dada imagem, um conjunto de 44 meta-descritores foi explorado. Nesse conjunto estão meta-descritores baseados no histograma de intensidade [68, 20], contraste e qualidade da imagem [69], matriz de co-ocorrência de tons de cinza [70], transformada rápida de *Fourier* (*Fast Fourier Transform* - FFT) [71] e descritores baseados em informações estatísticas das cores [50], levando em conta os canais Red, Green and Blue (espaço de cor RGB), e os canais Hue, Saturation and Value (espaço de cor HSV). A lista completa de todos os meta-descritores utilizados nos experimentos deste trabalho é apresentada na Tabela 5.1.

5.3 Meta-atributo Alvo

Neste trabalho, foram explorados três algoritmos de segmentação amplamente utilizados e com diferentes paradigmas: limiarização pelo método de Otsu, agrupamento de *pixels* pelo algoritmo *K-means* e segmentação supervisionada com o algoritmo SVM. Os algoritmos *K-means* e SVM foram implementados de modo a utilizar os valores RGB dos *pixels* da imagem, enquanto a abordagem utilizando o método de Otsu utiliza apenas uma imagem em tons de cinza como entrada. Todas as imagens das meta-bases foram segmentadas por esses três métodos de segmentação.

A qualidade da segmentação de cada imagem foi avaliada como **Adequada (AD)** ou **Não Adequada (NAD)**, para cada método de segmentação. Esse processo foi realizado separadamente por oito observadores (profissionais da área de VC), seguido por uma etapa de votação. Amostras com avaliações empatadas (4 **AD** e 4 **NAD**) foram consideradas indeterminadas e então substituídas pela moda estatística do respectivo rótulo (segmentador).

Portanto, cada meta-base possui três meta-atributos alvo binários diferentes, um para cada método de segmentação: **AD** indicando que o respectivo método de segmentação é adequado para o meta-exemplo (classe positiva) e **NAD** indicando que não é adequado (classe negativa).

As características principais das meta-bases são apresentadas na Tabela 5.2. A coluna **Exemplos** indica a quantidade de imagens (meta-exemplos) enquanto a coluna **Segmentadores** apresenta a distribuição de classes (**AD-NAD**) para cada um dos rótulos/métodos de segmentação. A última linha corresponde ao cenário com todas as imagens (**completa**), compondo a quarta meta-base.

Tabela 5.1 – Lista de todos os descritores de imagens usados como meta-descritores na abordagem proposta

| Num. | Tipo | Nome | Descrição |
|------|-----------|-----------------|---|
| 1 | Cor | meanB | Valor médio do canal azul (B) |
| 2 | Cor | stdB | Desvio padrão do canal azul (B) |
| 3 | Cor | varB | Variância do canal azul (B) |
| 4 | Cor | meanG | Valor médio do canal verde (G) |
| 5 | Cor | stdG | Desvio padrão do canal verde (G) |
| 6 | Cor | varG | Variância do canal verde (G) |
| 7 | Cor | meanH | Valor médio do canal matiz (H) |
| 8 | Cor | stdH | Desvio padrão do canal matiz (H) |
| 9 | Cor | varH | Variância do canal matiz (H) |
| 10 | Cor | meanR | Valor médio do canal vermelho (R) |
| 11 | Cor | stdR | Desvio padrão do canal vermelho (R) |
| 12 | Cor | varR | Variância do canal vermelho (R) |
| 13 | Cor | meanS | Valor médio do canal saturação (S) |
| 14 | Cor | stdS | Desvio padrão do canal saturação (S) |
| 15 | Cor | varS | Variância do canal saturação (S) |
| 16 | Cor | meanV | Valor médio do canal de luminosidade (V) |
| 17 | Cor | stdV | Desvio padrão do canal de luminosidade (V) |
| 18 | Cor | varV | Variância do canal de luminosidade (V) |
| 19 | FFT | engFFT | Energia da FFT |
| 20 | FFT | entFFT | Entropia da FFT |
| 21 | FFT | homFFT | Homogeneidade da FFT |
| 22 | FFT | ineFFT | Inércia da FFT |
| 23 | IntenHist | nNzGIntHist | Quantidade de grupos <i>não-zero</i> no histograma de intensidade |
| 24 | IntenHist | kurIntHist | Curtose do histograma de intensidade |
| 25 | IntenHist | pLgNzGIntHist | Pico do maior grupo <i>não-zero</i> no histograma de intensidade |
| 26 | IntenHist | pSmNzGIntHist | Pico do menor grupo <i>não-zero</i> no histograma de intensidade |
| 27 | IntenHist | skeIntHist | Obliquidade do histograma de intensidade |
| 28 | IntenHist | lenLgNzGIntHist | Comprimento do maior grupo <i>não-zero</i> no histograma de intensidade |
| 29 | IntenHist | lenSmNzGIntHist | Comprimento do menor grupo <i>não-zero</i> no histograma de intensidade |
| 30 | IntenHist | meanIntHist | Média da amplitude do histograma de intensidade |
| 31 | IntenHist | mdIntHist | Mediana da amplitude do histograma de intensidade |
| 32 | IntenHist | sdIntHist | Desvio padrão da amplitude do histograma de intensidade |
| 33 | IntenHist | varIntHist | Variância da amplitude do histograma de intensidade |
| 34 | IntenHist | nNzIntHist | Quantidade de índices <i>não-zero</i> no histograma de intensidade |
| 35 | IntenHist | peakIntHist | Pico do histograma de intensidade |
| 36 | CoMatriz | entGMat | Entropia da matriz de co-ocorrência |
| 37 | CoMatriz | homGMat | Homogeneidade da matriz de co-ocorrência |
| 38 | CoMatriz | ineGMat | Inércia da matriz de co-ocorrência |
| 39 | CoMatriz | corGMat | Correlação da matriz de co-ocorrência |
| 40 | CoMatriz | engGMat | Energia da matriz de co-ocorrência |
| 41 | Contraste | entInt | Entropia da intensidade da imagem original |
| 42 | Contraste | gConstFact | Fator de contraste global da imagem original (GCF) |
| 43 | Qualidade | stNatMeas | Medida de naturalidade estatística da imagem original (SNM) |
| 44 | Qualidade | measEnhan | Medida de melhoria da imagem original (EME) |

Tabela 5.2 – Especificações principais das meta-bases utilizadas nos experimentos

| Meta-base | Exemplos | Segmentadores | | | | | |
|-----------|----------|---------------|-----|------------|-----|-----|-----|
| | | Otsu | | K -means | | SVM | |
| | | AD | NAD | AD | NAD | AD | NAD |
| frango | 142 | 139 | 3 | 15 | 127 | 13 | 129 |
| ferida | 133 | 56 | 77 | 4 | 129 | 33 | 100 |
| nuvem | 91 | 51 | 40 | 63 | 28 | 70 | 21 |
| completa | 366 | 246 | 120 | 82 | 284 | 116 | 250 |

5.4 Meta-aprendizes

Devido à pequena quantidade de meta-exemplos, foi escolhida a metodologia de re-amostragem *Leave-One-Out Cross-Validation* para avaliar a performance preditiva dos meta-aprendizes. Durante a etapa de meta-aprendizado, é predita a probabilidade de um meta-exemplo pertencer a um valor de meta-atributo alvo específico. Para isso, foram utilizados como meta-aprendizes sete algoritmos de AM com diferentes vieses de aprendizagem: uma Regressão Logística (LogReg), uma Árvore de Decisão C4.5 (usando a implementação J48), um classificador *Naïve Bayes* (NB), o algoritmo de agrupamento k-NN, Redes Neurais utilizando o Modelo de Média (em inglês *Neural Networks Using Model Averaging* - avNNet), *Random Forest* (RF) e *Support Vector Machine* (SVM). Todos eles foram implementados em ambiente R com o auxílio do pacote `mlr` (*Machine Learning in R*)² (e suas dependências), utilizando configuração padrão para os parâmetros.

Uma vez que as meta-bases não estão balanceadas (Tabela 5.2), é interessante utilizar *baselines* como comparação. Dois meta-modelos triviais foram usados como *baselines* para os experimentos: O meta-modelo **Maioria**, que sempre prediz a classe majoritária e o meta-modelo **Aleatório** que prediz uma classe válida aleatória. Nesse tipo de avaliação, espera-se que os meta-modelos gerados por algoritmos de AM apresentem desempenho melhor que os dois meta-modelos triviais.

5.5 Medidas de Performance

O problema tratado neste trabalho foi modelado como um conjunto de problemas binários, utilizando uma estratégia de Relevância Binária. A abordagem de Relevância Binária (em inglês *Binary Relevance*) é a mais simples e mais direta forma de realizar classificação multi-rótulo [72].

Para medir o erro da predição em problemas multi-rótulo pode ser utilizada a medida *Hamming Loss*. Portanto, o inverso do valor de *Hamming Loss* é usado como Acurácia Preditiva neste trabalho. Também foram extraídas, de cada um dos problemas de classificação binários, as taxas de Verdadeiros Positivos e Negativos (VPTaxa e VNTaxa), a Área Abaixo da Curva ROC (AAC) e a métrica *F-Measure*. Para avaliar os meta-aprendizes, foi calculada a média de cada métrica para cada um dos três problemas de classificação binários (os três segmentadores).

A importância dos meta-descritores também foi avaliada, porém apenas para o meta-modelos gerados pelo algoritmo RF (essa escolha é justificada no Capítulo 6). O algoritmo RF utiliza o índice Gini como uma medida para selecionar o melhor ponto de separação durante a construção das árvores [73]. O índice Gini mede a impureza e a irregularidade dos dados, ou seja, quanto maior for a diminuição no valor de Gini ao

² <https://github.com/mlr-org/mlr>

se ramificar a árvore em uma determinada variável, mais importante é a variável em questão. Portanto, para se observar o valor de importância de cada meta-descritor para os meta-modelos gerados pelo algoritmo RF, foi extraída a métrica *Mean Decrease Gini*.

6 RESULTADOS E DISCUSSÃO

Neste capítulo, os resultados principais dos experimentos são apresentados e discutidos. Foram executados sete meta-aprendizes com diferentes vieses de aprendizagem nas quatro meta-bases. As métricas de performance para cada cenário são demonstradas através de gráficos de radar (Figuras 6.1, 6.2, 6.3 e 6.4). Cada linha colorida nas figuras representa um meta-modelo e os vértices de cada polígono indicam as diferentes medidas de performance. Quanto maior os valores dos vértices (e conseqüentemente a área do polígono), melhor é o meta-modelo. As figuras também demonstra a performance dos dois *baselines*: o meta-modelo Aleatório (linha cinza clara) e o meta-modelo Maioria (linha preta).

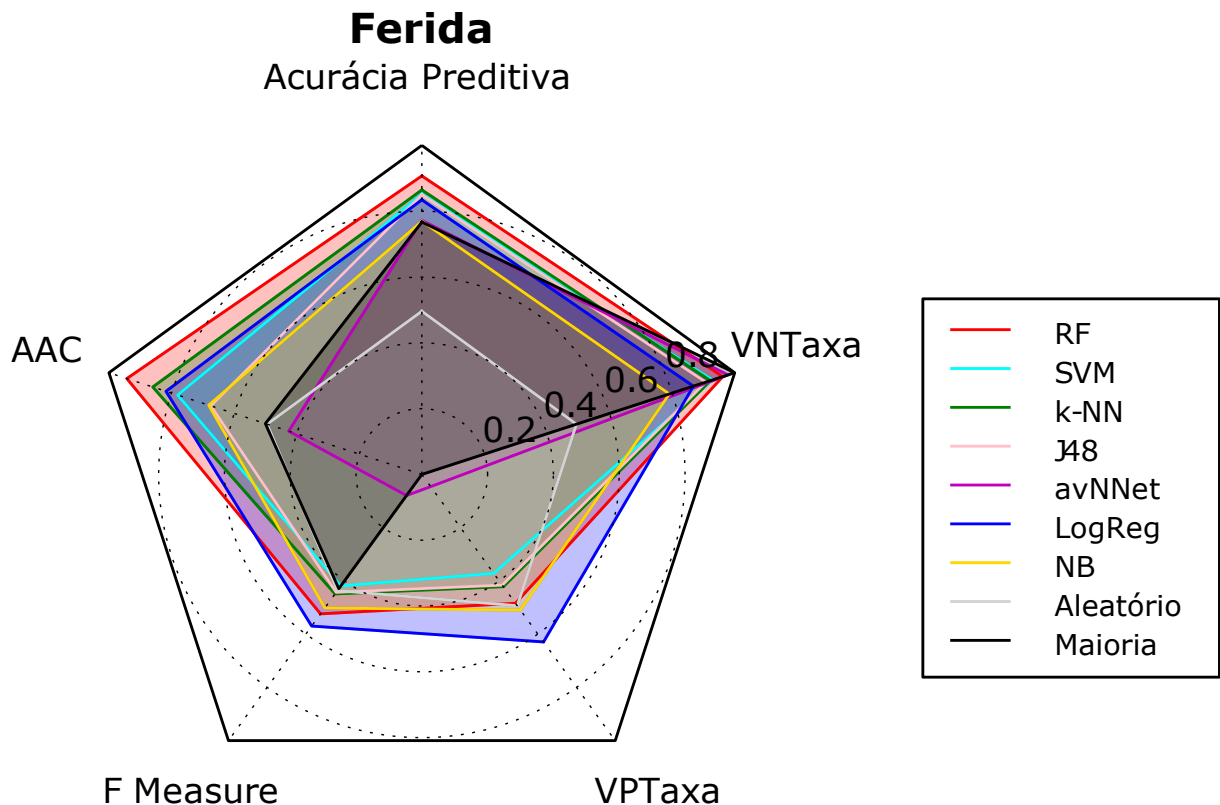


Figura 6.1 – Performance média dos meta-modelos da meta-base *ferida* de acordo com cinco diferentes medidas: Acurácia Preditiva, Área Abaixo da Curva ROC (AAC), *F-Measure*, Taxa de Verdadeiros Positivos (VPTaxa) e Taxa de Verdadeiros Negativos (VNTaxa)

Olhando para os resultados da meta-base *ferida* (Figura 6.1), é possível observar que a maior área é gerada pelo polígono vermelho, que representa o meta-modelo gerado pelo algoritmo RF. Esse meta-modelo apresenta os melhores valores para acurácia 0.907, AAC 0.942 e VNTaxa 0.961. Os melhores resultados para a métricas *F-Measure* (0.569) e VPTaxa (0.629) foram obtidos pelo meta-modelo linear (LogReg). O fato de que nenhum

meta-modelo apresentou valor F -Measure maior do que 0.6 está diretamente relacionado à distribuição das classes para o método de segmentação K -means: apenas 4 imagens possuem o rótulo **AD** enquanto 129 possuem o rótulo **NAD**. Mesmo assim, no geral, o algoritmo RF apresentou resultados melhores do que os outros meta-modelos.




Figura 6.2 – Performance média dos meta-modelos da meta-base **frango** de acordo com cinco diferentes medidas: Acurácia Preditiva, Área Abaixo da Curva ROC (AAC), F -Measure, Taxa de Verdadeiros Positivos (VPTaxa) e Taxa de Verdadeiros Negativos (VNTaxa)

Levando em conta a meta-base **frango** (Figura 6.2), o meta-modelo construído com o algoritmo SVM foi o melhor em termos de acurácia (0.960) e F -Measure (0.786), seguido pelo algoritmo RF (acurácia = 0.955, F -Measure = 0.780). O meta-modelo linear (LogReg) apresentou os melhores resultados nas métricas AAC (0.917) e VPTaxa (0.893), além de possuir a maior área entre todos os meta-modelos (polígono azul). É interessante notar que o meta-modelo mais simples (LogReg) é a melhor escolha para essa meta-base (que é também a mais simples das meta-bases).

Analisando o cenário da meta-base **nuvem** (Figura 6.3), pode-se observar que os meta-modelos obtiveram desempenhos similares. Os algoritmos RF e SVM empataram como os melhores em termos de acurácia (0.743), ACC (0.675) e F -Measure (0.817). O meta-modelo gerado pelo algoritmo NB foi o melhor de acordo com a métrica VNTaxa (0.619 - linha amarela), enquanto para a métrica VPTaxa o melhor algoritmo foi o avNNet (0.994 - linha roxa) empatado com o *baseline* Maioria. Em geral, os melhores meta-modelos para essa meta-base foram os gerados pelos algoritmos SVM e RF.

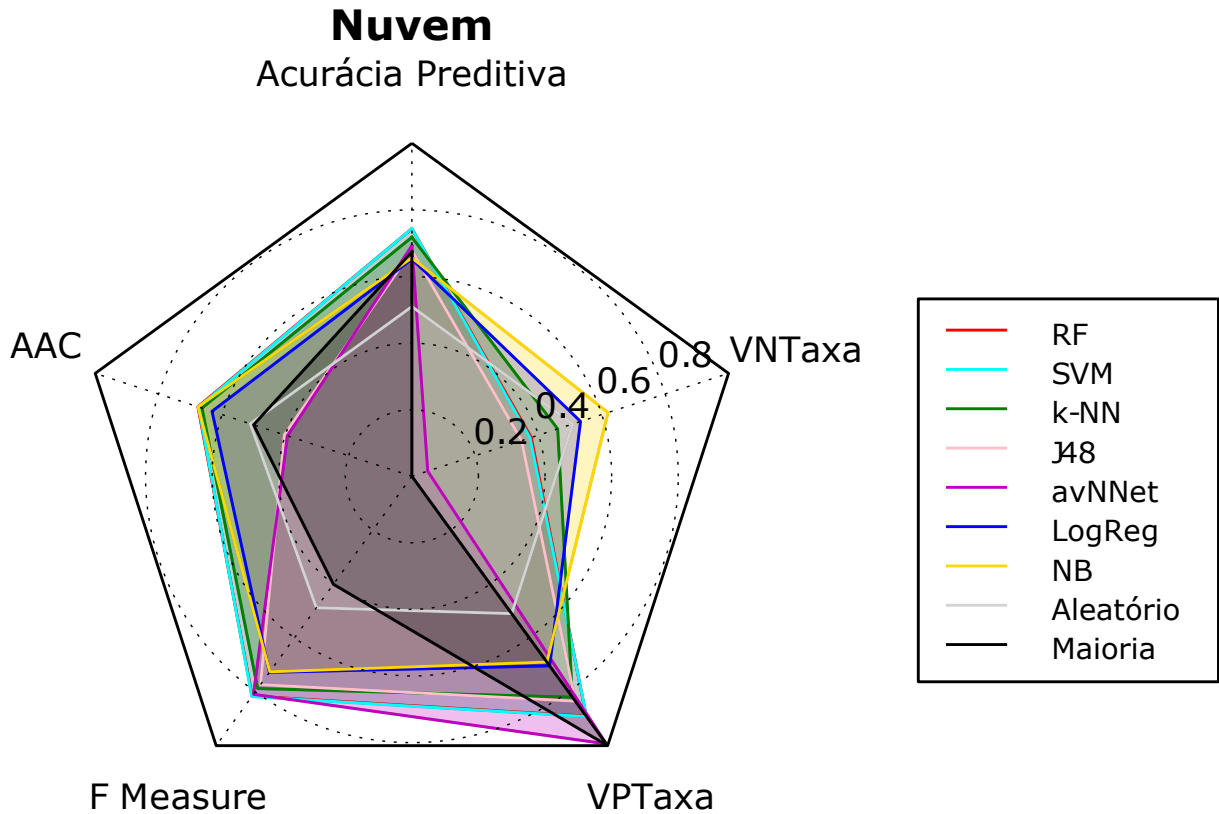


Figura 6.3 – Performance média dos meta-modelos da meta-base nuvem de acordo com cinco diferentes medidas: Acurácia Preditiva, Área Abaixo da Curva ROC (AAC), *F-Measure*, Taxa de Verdadeiros Positivos (VPTaxa) e Taxa de Verdadeiros Negativos (VNTaxa)

Levando em conta o cenário geral (meta-base completa) (Figura 6.4), é possível observar que, ao induzir modelos com todas as imagens disponíveis (de diferentes problemas), o algoritmo RF obteve os melhores valores para todas as métricas de avaliação. O polígono vermelho possui a maior área e abrange todos os outros polígonos. A informação fornecida pela meta-base completa melhorou a performance do RF, corrigindo algumas previsões anteriormente errôneas. Esse assunto será melhor discutido na Seção 6.2.

Os meta-modelos gerados pelo algoritmo RF obtiveram bons resultados em 3/4 dos cenários estudados. Na Tabela 6.1 é apresentada uma comparação dos resultados dos meta-modelos RF com os dois *baselines* utilizados nos experimentos. É possível notar que o meta-modelo RF supera os dois *baselines* em termos de acurácia, AAC e *F-Measure*. Em todos os casos, os polígonos gerados pelos *baselines* (cinza claro e preto) nas Figuras 6.1, 6.2, 6.3 e 6.4 estão contidos nos polígonos que representam o melhor meta-modelo da respectiva meta-base. Isto é, como esperado, os meta-modelos gerados pelos algoritmos de AM foram melhores que os *baselines*. Em geral, o algoritmo que obteve melhor desempenho foi o RF, portanto, apenas os resultados relacionados a ele serão discutidos nas próximas seções.

Completa

Acurácia Preditiva

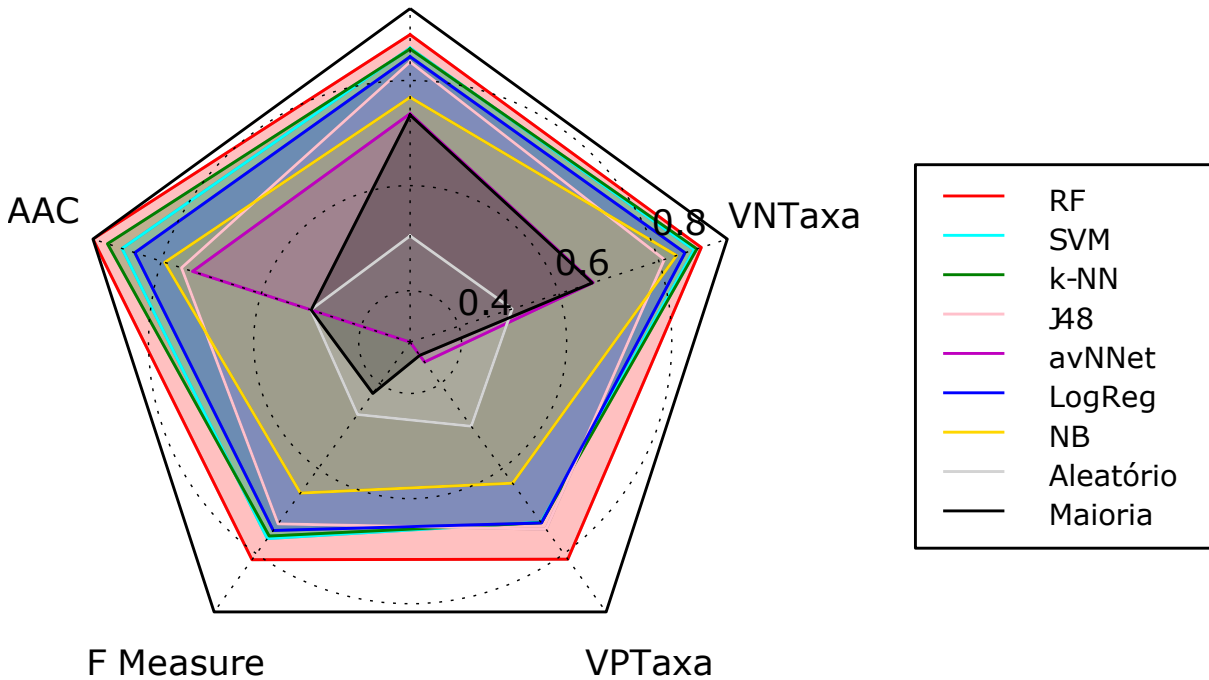


Figura 6.4 – Performance média dos meta-modelos da meta-base **completa** de acordo com cinco diferentes medidas: Acurácia Preditiva, Área Abaixo da Curva ROC (AAC), *F-Measure*, Taxa de Verdadeiros Positivos (VPTaxa) e Taxa de Verdadeiros Negativos (VNTaxa)

Tabela 6.1 – Performance dos meta-modelos gerados pelo algoritmo *Random Forest* comparada a dos dois *baselines*: Aleatório e Maioria

| Meta-base | Algoritmo | Acurácia | AAC | <i>F-Measure</i> | VPTaxa | VNTaxa |
|-----------|-----------|----------------|----------------|------------------|----------------|----------------|
| frango | Aleatório | 0.51064 | 0.48669 | 0.39066 | 0.51154 | 0.47913 |
| frango | Maioria | 0.92723 | 0.50000 | 0.48093 | 0.33333 | 0.66667 |
| frango | RF | 0.95549 | 0.83452 | 0.77959 | 0.73504 | 0.65367 |
| nuvem | Aleatório | 0.50952 | 0.51047 | 0.48811 | 0.50985 | 0.50811 |
| nuvem | Maioria | 0.67399 | 0.50000 | 0.40101 | 1.00000 | 0.00000 |
| nuvem | RF | 0.74359 | 0.67570 | 0.81606 | 0.89035 | 0.37698 |
| ferida | Aleatório | 0.49599 | 0.49432 | 0.43637 | 0.49347 | 0.49402 |
| ferida | Maioria | 0.76692 | 0.50000 | 0.42941 | 0.00000 | 1.00000 |
| ferida | RF | 0.90727 | 0.94280 | 0.52381 | 0.48413 | 0.96169 |
| completa | Aleatório | 0.50413 | 0.50079 | 0.47239 | 0.49992 | 0.50633 |
| completa | Maioria | 0.73406 | 0.50000 | 0.42285 | 0.33333 | 0.66667 |
| completa | RF | 0.88707 | 0.93658 | 0.81384 | 0.81264 | 0.88463 |

6.1 Importância dos Meta-Descritores

Foi extraído o valor de importância de cada meta-descritor nos modelos RF usando a métrica *Mean Decrease Gini* (MDGini).

O algoritmo RF utiliza o índice Gini como uma medida para selecionar o melhor ponto de separação durante a construção das árvores. A Figura 6.5 apresenta, para cada




Figura 6.5 – Valor de *Mean Decrease Gini* para todas os meta-descritores extraídos dos meta-modelos RF

meta-base, a contribuição de cada meta-descritor durante o processo de recomendação do algoritmo. Também é possível observar essas informações com mais detalhes nas Tabelas 6.2, 6.3, 6.4 e 6.5.

Na meta-base **ferida** (Tabela 6.2), as características da cor vindas do espaço de cor HSV foram de grande importância para os algoritmos de segmentação Otsu e SVM, especialmente os canais Matiz (H) e Saturação (S). Isso faz sentido, uma vez que nessa meta-base existe uma grande diferença de saturação entre ROI e *background*, como pode ser visto na Figura 5.1. A métrica *Measure of Enhancement* (EME) também obteve valores altos de importância para os algoritmos Otsu e SVM. Para o algoritmo de segmentação *K-means*, apenas o pico do menor grupo de não-zeros no histograma de intensidade obteve destaque.

Já nos resultados da meta-base **frango** (Tabela 6.3), os descritores extraídos do canal azul (B) do espaço de cor RGB se destacaram em importância com relação aos

Tabela 6.2 – Valor de *Mean Decrease Gini* dos cinco meta-descritores mais importantes para cada segmentador na meta-base **ferida**

| Otsu | | | K-means | | | SVM | | |
|-----------|----------------|--------|-----------|----------------|--------|-----------|----------------|--------|
| Tipo | Meta-descritor | MDGini | Tipo | Meta-descritor | MDGini | Tipo | Meta-descritor | MDGini |
| Cor | stdS | 3.547 | IntenHist | pSmNzGIntHist | 1.263 | Qualidade | measEnhan | 3.946 |
| Cor | varS | 3.519 | Cor | varS | 0.419 | Cor | stdS | 3.076 |
| Qualidade | measEnhan | 3.020 | Cor | stdS | 0.415 | Cor | varS | 3.037 |
| Cor | meanH | 2.823 | Cor | stdR | 0.343 | IntenHist | pSmNzGIntHist | 2.225 |
| CoMatriz | entGMat | 2.165 | Cor | varR | 0.324 | Cor | varH | 2.207 |

Tabela 6.3 – Valor de *Mean Decrease Gini* dos cinco meta-descritores mais importantes para cada segmentador na meta-base **frango**

| Otsu | | | K-means | | | SVM | | |
|-----------|-----------------|--------|-----------|----------------|--------|-----------|----------------|--------|
| Tipo | Meta-descritor | MDGini | Tipo | Meta-descritor | MDGini | Tipo | Meta-descritor | MDGini |
| CoMatriz | homGMat | 0.316 | Cor | varR | 1.465 | Cor | stdB | 4.032 |
| IntenHist | lenLgNzGIntHist | 0.292 | IntenHist | pSmNzGIntHist | 1.456 | Cor | varB | 4.011 |
| IntenHist | kurIntHist | 0.270 | Cor | stdR | 1.437 | Cor | meanS | 0.831 |
| IntenHist | nNzIntHist | 0.241 | CoMatriz | entGMat | 1.239 | CoMatriz | entGMat | 0.797 |
| Cor | stdV | 0.237 | Cor | varB | 1.059 | Contraste | entInt | 0.616 |

outros, principalmente para o algoritmo de segmentação SVM. Isso provavelmente possui relação com o *background* azul das imagens dessa meta-base. Alguns picos de importância também estiverem presentes em características do canal vermelho (R), pico do menor grupo de não-zeros no histograma de intensidade e entropia da matriz de co-ocorrência de tons de cinza, todos para o algoritmo de segmentação *K-means*. Uma vez que o índice Gini é relacionado com a seleção do melhor ponto de separação durante a construção da árvore, a falta de um descritor de destaque para o segmentador Otsu tem a ver com a distribuição das classes (139 **NAD** e 3 **AD**).

Tabela 6.4 – Valor de *Mean Decrease Gini* dos cinco meta-descritores mais importantes para cada segmentador na meta-base **nuvem**

| Otsu | | | K-means | | | SVM | | |
|-----------|----------------|--------|-----------|----------------|--------|-----------|----------------|--------|
| Tipo | Meta-descritor | MDGini | Tipo | Meta-descritor | MDGini | Tipo | Meta-descritor | MDGini |
| IntenHist | meanIntHist | 2.981 | IntenHist | kurIntHist | 3.120 | IntenHist | meanIntHist | 1.458 |
| FFT | ineFFT | 2.233 | Qualidade | stNatMeas | 2.188 | FFT | entFFT | 1.386 |
| IntenHist | kurIntHist | 1.901 | IntenHist | skeIntHist | 2.148 | IntenHist | kurIntHist | 1.243 |
| Cor | meanH | 1.567 | IntenHist | sdIntHist | 1.201 | Contraste | gConstFact | 1.215 |
| FFT | engFFT | 1.524 | FFT | ineFFT | 1.151 | CoMatriz | entGMat | 1.085 |

A distribuição da importância dos meta-descritores na meta-base **nuvem** (Tabela 6.4) foi caótica, provavelmente devido à sua complexidade. No entanto, para o algoritmo *K-means*, as características mais relevantes em geral foram as relacionadas ao histograma de intensidade, especificamente os valores de curtose (*kurtosis*) e obliquidade (*skewness*). A medida de naturalidade estatística (*Statistical Naturalness Measure* - SNM) também foi necessária para o K-means. Para os algoritmos de segmentação Otsu e SVM, as características do histograma de intensidade também foram relevantes, seguidas pelos valores de Inércia, Entropia e Energia da FFT.

Finalmente, levando em conta a meta-base **completa** (Tabela 6.5), o meta-descritor mais importante foi o EME para o algoritmo SVM, seguido pelas características da cor nos canais Azul (B) e Matiz (H) e pelos valores de Homogeneidade e Entropia da FFT (para os algoritmos Otsu e *K-means*).

De maneira geral, praticamente todos meta-descritores tiveram alguma importância para a meta-base **completa** e, apesar da existência de alguns picos, nenhuma caracte-

Tabela 6.5 – Valor de *Mean Decrease Gini* dos cinco meta-descritores mais importantes para cada segmentador na meta-base *completa*

| Otsu | | | K-means | | | SVM | | |
|------|----------------|--------|-----------|----------------|--------|-----------|----------------|--------|
| Tipo | Meta-descritor | MDGini | Tipo | Meta-descritor | MDGini | Tipo | Meta-descritor | MDGini |
| Cor | meanB | 7.967 | FFT | homFFT | 5.877 | Qualidade | measEnhan | 9.970 |
| FFT | homFFT | 7.524 | FFT | entFFT | 5.683 | Cor | stdS | 6.652 |
| Cor | meanH | 7.189 | Cor | meanV | 5.236 | Cor | varS | 6.640 |
| Cor | stdS | 6.567 | CoMatriz | ineGMat | 5.118 | FFT | entFFT | 5.952 |
| Cor | varS | 6.501 | IntenHist | peakIntHist | 4.881 | FFT | homFFT | 5.354 |

terística se destacou em todas as meta-bases.

6.2 Predições do *Random Forest*

Na Figura 6.6 são apresentadas as predições obtidas pelos meta-modelos gerados pelo algoritmo RF. O eixo X mostra cada uma das amostras (imagens) enquanto o eixo Y apresenta os algoritmos de segmentação (Otsu, SVM, and *K-means*). Os retângulos vermelhos indicam predições erradas, enquanto os retângulos brancos indicam predições corretas.




Figura 6.6 – Predições para cada amostra, levando em conta a meta-base *completa* (em cima) e as outras três meta-bases separadamente (embaixo)

Dessa maneira, as amostras problemáticas podem ser reconhecidas por uma linha vermelha que significa que elas foram preditas incorretamente para todos os algoritmos de segmentação. Na meta-base *ferida*, a única amostra problemática (267) foi encontrada quando o meta-modelo foi construído para cada meta-base separadamente. Essa amostra pode ser vista na Figura 6.7. A segmentação da amostra 267 foi avaliada pelos observadores como **AD** para todos os métodos de segmentação, porém o meta-modelo equivocadamente previu como **NAD**.

A maioria das amostras problemáticas foram encontradas na meta-base *nuvem* (a mais complexa para segmentar e avaliar). Três amostras problemáticas foram identificadas (18,25,38) no meta-modelo construído para cada meta-base separadamente. Levando em conta a meta-base *completa*, esse número aumentou para nove (7,18,25,26,27,38,45,50,74) imagens de nuvens. As amostras 18, 25 e 38 apareceram nos dois casos, sendo avaliadas




Figura 6.7 – Amostras problemáticas 18, 25 e 38: originais e segmentadas

como **NAD** pelos observadores (para todos os métodos de segmentação) e preditas como **AD** pelos meta-modelos. Essas amostras também podem ser vistas na Figura 6.7.

7 CONCLUSÃO

Neste trabalho, o problema de selecionar um algoritmo de segmentação adequado para uma imagem (ou para um grupo de imagens similares) foi abordado utilizando Meta-Aprendizado, um conceito que tem sido recentemente aplicado na área de AM para resolver o problema da seleção de algoritmos.

Foi então proposto um *framework* para recomendar algoritmos de segmentação de imagens baseado em Meta-Aprendizado, utilizando um conjunto de 44 meta-descritores para caracterizar imagens e prover as informações necessárias para prever quais algoritmos de segmentação são adequados ou não adequados para uma nova imagem de entrada.

Os experimentos foram realizados com quatro meta-bases, utilizando sete algoritmos de AM como meta-aprendizes (ou meta-recomendadores). Além disso, dois *baselines* também foram utilizados como meta-aprendizes para comparações. As imagens utilizadas, coloridas e representando diversos problemas reais de segmentação, foram segmentadas por três algoritmos de segmentação amplamente utilizados e com diferentes paradigmas: limiarização pelo método de Otsu, agrupamento de *pixels* pelo algoritmo *K-means* e segmentação supervisionada com o algoritmo SVM.

Mesmo sem utilizar abordagens de seleção de meta-descritores ou otimização de parâmetros, os meta-modelos obtiveram alta acurácia. Os meta-modelos construídos com o algoritmo *Random Forest* foram capazes de recomendar algoritmos de segmentação com altos valores de acurácia preditiva (0.887), AAC (0.936) e *F-Measure* (0.813), obtendo o melhor desempenho como meta-recomendador. Isso indica um alto poder discriminativo dos meta-descritores escolhidos para modelar o problema, além de demonstrar que é possível recomendar algoritmos de segmentação de imagens com uma performance adequada utilizando Meta-Aprendizado, representando uma contribuição para as áreas de Processamento de Imagens e Visão Computacional.

7.1 Trabalhos Futuros

Como trabalhos futuros, além de implementar mais meta-descritores e algoritmos de segmentação, seria interessante testar a viabilidade de utilizar métodos não supervisionados na etapa de avaliar a segmentação. Isso facilitaria muito o processo de rotulação, tornando possível aumentar significativamente o tamanho das meta-bases e a quantidade de algoritmos de segmentação. Outra opção interessante seria utilizar bases públicas de segmentação de imagens que já possuam modelo ouro ou, até mesmo, bases de *benchmark* de segmentação.

REFERÊNCIAS

- [1] WANG, X.-Y.; WANG, T.; BU, J. Color image segmentation using pixel wise support vector machine classification. *Pattern Recogn.*, Elsevier Science Inc., New York, NY, USA, v. 44, n. 4, p. 777–787, abr. 2011. ISSN 0031-3203.
- [2] DAVIES, E. Chapter 1 - vision, the challenge. In: DAVIES, E. (Ed.). *Computer and Machine Vision (Fourth Edition)*. Fourth edition. Boston: Academic Press, 2012. p. 1 – 14. ISBN 978-0-12-386908-1.
- [3] SCHAEFER, G. et al. Colour and contrast enhancement for improved skin lesion segmentation. *Computerized Medical Imaging and Graphics*, v. 35, n. 2, p. 99 – 104, 2011. ISSN 0895-6111. Advances in Skin Cancer Image Analysis.
- [4] SEIXAS, J. et al. Color energy as a seed descriptor for image segmentation with region growing algorithms on skin wound images. In: *e-Health Networking, Applications and Services (Healthcom), 2014 IEEE 16th International Conference on*. [S.l.: s.n.], 2014. p. 387–392.
- [5] AVENDI, M.; KHERADVAR, A.; JAFARKHANI, H. A combined deep-learning and deformable-model approach to fully automatic segmentation of the left ventricle in cardiac {MRI}. *Medical Image Analysis*, v. 30, p. 108 – 119, 2016. ISSN 1361-8415.
- [6] KOVACS, G.; HAJDU, A. A self-calibrating approach for the segmentation of retinal vessels by template matching and contour reconstruction. *Medical Image Analysis*, v. 29, p. 24 – 46, 2016. ISSN 1361-8415.
- [7] BARBIN, D. F. et al. Digital image analyses as an alternative tool for chicken quality assessment. *Biosystems Engineering*, v. 144, p. 85 – 93, 2016. ISSN 1537-5110.
- [8] CHEN, K.; QIN, C. Segmentation of beef marbling based on vision threshold. *Computers and Electronics in Agriculture*, Elsevier, v. 62, n. 2, p. 223–230, 2008.
- [9] MURILLO-BRACAMONTES, E. A. et al. Implementation of hough transform for fruit image segmentation. *Procedia Engineering*, v. 35, n. 0, p. 230 – 239, 2012. ISSN 1877-7058. International Meeting of Electrical Engineering Research 2012.
- [10] DUTTA, M. K. et al. Image processing based method to assess fish quality and freshness. *Journal of Food Engineering*, v. 177, p. 50 – 58, 2016. ISSN 0260-8774.
- [11] SAMMOUDA, R. et al. Agriculture satellite image segmentation using a modified artificial hopfield neural network. *Computers in Human Behavior*, v. 30, p. 436 – 441, 2014. ISSN 0747-5632.
- [12] BHANDARI, A.; KUMAR, A.; SINGH, G. Tsallis entropy based multilevel thresholding for colored satellite image segmentation using evolutionary algorithms. *Expert Systems with Applications*, v. 42, n. 22, p. 8707 – 8730, 2015. ISSN 0957-4174.
- [13] SURESH, S.; LAL, S. An efficient cuckoo search algorithm based multilevel thresholding for segmentation of satellite images using different objective functions. *Expert Systems with Applications*, v. 58, p. 184 – 209, 2016. ISSN 0957-4174.

- [14] BASAEED, E.; BHASKAR, H.; AL-MUALLA, M. Supervised remote sensing image segmentation using boosted convolutional neural networks. *Knowledge-Based Systems*, v. 99, p. 19 – 27, 2016. ISSN 0950-7051.
- [15] SAG, T.; ÇUNKAS, M. Color image segmentation based on multiobjective artificial bee colony optimization. *Applied Soft Computing*, v. 34, n. 0, p. 389 – 401, 2015. ISSN 1568-4946.
- [16] FERNANDEZ, M. A.; LOPES, R. M.; HIRATA, N. S. T. Image segmentation assessment from the perspective of a higher level task. In: *2015 28th SIBGRAPI Conference on Graphics, Patterns and Images*. [S.l.: s.n.], 2015. p. 111–118. ISSN 1530-1834.
- [17] WOLPERT, D. H. The lack of a priori distinctions between learning algorithms. *Neural Computation*, MIT Press, Cambridge, MA, USA, v. 8, n. 7, p. 1341–1390, out. 1996. ISSN 0899-7667.
- [18] TAKEMOTO, S.; YOKOTA, H. Algorithm selection for intracellular image segmentation based on region similarity. In: *2009 Ninth International Conference on Intelligent Systems Design and Applications*. [S.l.: s.n.], 2009. p. 1413–1418. ISSN 2164-7143.
- [19] YONG, X. et al. Learning-based algorithm selection for image segmentation. *Pattern Recognition Letters*, v. 26, n. 8, p. 1059 – 1068, 2005. ISSN 0167-8655.
- [20] CAMPOS, G. F. C. et al. Supervised approach for indication of contrast enhancement in application of image segmentation. In: *MMEDIA 2016, The Eighth International Conferences on Advances in Multimedia*. [S.l.: s.n.], 2016. p. 12–18. ISSN 2308-4448.
- [21] BRAZDIL, P. et al. *Metalearning: Applications to Data Mining*. 2. ed. [S.l.]: Springer Verlag, 2009.
- [22] ALI, S.; SMITH-MILES, K. A. A meta-learning approach to automatic kernel selection for support vector machines. *Neurocomputing*, v. 70, n. 13, p. 173–186, 2006.
- [23] ROSSI, A. L. D. et al. Metastream: A meta-learning based method for periodic algorithm selection in time-changing data. *Neurocomputing*, v. 127, p. 52 – 64, 2014. ISSN 0925-2312.
- [24] REIF, M.; SHAFAIT, F.; DENGEL, A. Meta-learning for evolutionary parameter optimization of classifiers. *Machine Learning*, Springer US, v. 87, p. 357–380, 2012.
- [25] ATTIG, A.; PERNER, P. A study on the case image description for learning the model of the watershed segmentation. *Transactions on Case-Based Reasoning*, ibai Publishing, v. 2, n. 1, p. 41–53, 2009.
- [26] MARAKEBY, H. A.; ZAKI, M.; SAMIR, I. S. A generalized object detection system using automatic feature selection. In: *2010 10th International Conference on Intelligent Systems Design and Applications*. [S.l.: s.n.], 2010. p. 839–844. ISSN 2164-7143.

- [27] YAMAGUCHI, T. et al. Application of particle swarm optimization to similar image search on satellite sensor data. In: *Soft Computing and Intelligent Systems (SCIS) and 13th International Symposium on Advanced Intelligent Systems (ISIS), 2012 Joint 6th International Conference on*. [S.l.: s.n.], 2012. p. 1573–1577.
- [28] LEE, J.-S.; OLAFSSON, S. A meta-learning approach for determining the number of clusters with consideration of nearest neighbors. *Information Sciences*, v. 232, p. 208–224, 2013. ISSN 0020-0255.
- [29] MIRANDA, P. B. et al. A hybrid meta-learning architecture for multi-objective optimization of {SVM} parameters. *Neurocomputing*, v. 143, p. 27–43, 2014. ISSN 0925-2312.
- [30] FERRARI, D. G.; CASTRO, L. N. de. Clustering algorithm selection by meta-learning systems: A new distance-based problem characterization and ranking combination methods. *Information Sciences*, v. 301, p. 181–194, 2015. ISSN 0020-0255.
- [31] SOARES, C.; BRAZDIL, P. B.; KUBA, P. A meta-learning method to select the kernel width in support vector regression. *Machine Learning*, v. 54, n. 3, p. 195–209, 2004.
- [32] SOARES, C.; BRAZDIL, P. B. Selecting parameters of svm using meta-learning and kernel matrix-based meta-features. In: *Proceedings of the 2006 ACM symposium on Applied computing*. [S.l.]: ACM Press, 2006. (SAC'06), p. 564–568.
- [33] GOMES, T. A. F. et al. Combining meta-learning and search techniques to select parameters for support vector machines. *Neurocomputing*, Elsevier Science Publishers B. V., Amsterdam, The Netherlands, The Netherlands, v. 75, n. 1, p. 3–13, jan. 2012.
- [34] MIRANDA, P. B. C. et al. An experimental study of the combination of meta-learning with particle swarm algorithms for svm parameter selection. *Lecture Notes in Computer Science*, Springer Verlag, v. 7335 LNCS, n. PART 3, p. 562–575, 2012.
- [35] GONZALEZ, R. C.; WOODS, R. E. *Processamento Digital De Imagens*. [S.l.]: ADDISON WESLEY BRA, 2010. ISBN 9788576054016.
- [36] NIXON, M.; AGUADO, A. *Feature Extraction and Image Processing*. [S.l.]: Newnes, 2002. (Electronics & Electrical). ISBN 9780750650786.
- [37] AZEVEDO, E.; CONCI, A. *Computação gráfica: teoria e prática*. [S.l.]: Elsevier, 2003. ISBN 9788535212525.
- [38] SNASEL, V. et al. International conference on communications, management, and information technology (iccmitt'2015) survey on image segmentation techniques. *Procedia Computer Science*, v. 65, p. 797 – 806, 2015. ISSN 1877-0509.
- [39] CHAUHAN, A. S.; SILAKARI, S.; DIXIT, M. Image segmentation methods: A survey approach. In: *Communication Systems and Network Technologies (CSNT), 2014 Fourth International Conference on*. [S.l.: s.n.], 2014. p. 929–933.

- [40] RAUT, S. A. et al. Image segmentation 150; a state-of-art survey for prediction. In: *Advanced Computer Control, 2009. ICACC '09. International Conference on*. [S.l.: s.n.], 2009. p. 420–424.
- [41] SEZGIN, M.; SANKUR, B. Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging*, v. 13, n. 1, p. 146–168, 2004.
- [42] OTSU, N. A Threshold Selection Method from Gray-level Histograms. *IEEE Transactions on Systems, Man and Cybernetics*, IEEE, v. 9, n. 1, p. 62–66, jan. 1979. ISSN 0018-9472.
- [43] SAHOO, P.; SOLTANI, S.; WONG, A. A survey of thresholding techniques. *Computer Vision, Graphics, and Image Processing*, v. 41, n. 2, p. 233 – 260, 1988. ISSN 0734-189X.
- [44] VELMURUGAN, T. Performance based analysis between k-means and fuzzy c-means clustering algorithms for connection oriented telecommunication data. *Applied Soft Computing*, v. 19, n. 0, p. 134 – 146, 2014. ISSN 1568-4946.
- [45] YAO, H. et al. An improved -means clustering algorithm for fish image segmentation. *Mathematical and Computer Modelling*, v. 58, n. 3–4, p. 790 – 798, 2013. ISSN 0895-7177. Computer and Computing Technologies in Agriculture 2011 and Computer and Computing Technologies in Agriculture 2012.
- [46] SHENOY, P. D. et al. Eleventh international conference on communication networks, iccn 2015, august 21-23, 2015, bangalore, india eleventh international conference on data mining and warehousing, icdmw 2015, august 21-23, 2015, bangalore, india eleventh international conference on image and signal processing, icisp 2015, august 21-23, 2015, bangalore, india image segmentation using k -means clustering algorithm and subtractive clustering algorithm. *Procedia Computer Science*, v. 54, p. 764 – 771, 2015. ISSN 1877-0509.
- [47] KOTSIANTIS, S. B. Supervised machine learning: A review of classification techniques. In: *Proceedings of the 2007 Conference on Emerging Artificial Intelligence Applications in Computer Engineering: Real Word AI Systems with Applications in eHealth, HCI, Information Retrieval and Pervasive Technologies*. Amsterdam, The Netherlands, The Netherlands: IOS Press, 2007. p. 3–24. ISBN 978-1-58603-780-2.
- [48] BAI, X.; WANG, W. Saliency-svm: An automatic approach for image segmentation. *Neurocomputing*, v. 136, p. 243 – 255, 2014. ISSN 0925-2312.
- [49] SAKTHIVEL, K.; NALLUSAMY, R.; KAVITHA, C. Color image segmentation using svm pixel classification image. *World Academy of Science, Engineering and Technology, International Journal of Computer, Electrical, Automation, Control and Information Engineering*, v. 8, n. 10, p. 1919–1925, 2015.
- [50] LI, D. et al. Pornographic images recognition based on spatial pyramid partition and multi-instance ensemble learning. *Knowledge-Based Systems*, v. 84, p. 214 – 223, 2015. ISSN 0950-7051.

- [51] MIN, B. S. et al. A novel method of determining parameters of clahe based on image entropy. *International Journal of Software Engineering and Its Applications*, v. 7, n. 5, p. 113–120, 2013.
- [52] MATKOVIĆ, K. et al. Global contrast factor - a new approach to image contrast. In: *Proceedings of the First Eurographics Conference on Computational Aesthetics in Graphics, Visualization and Imaging*. Aire-la-Ville, Switzerland, Switzerland: Eurographics Association, 2005. (Computational Aesthetics'05), p. 159–167. ISBN 3-905673-27-4.
- [53] ISMAIL, N. H. B. et al. An analysis of image quality assessment algorithm to detect the presence of unnatural contrast enhancement. *Journal of Theoretical and Applied Information Technology*, Journal of Theoretical and Applied Information, v. 83, n. 3, p. 415, 2016.
- [54] MARSLAND, S. *Machine learning: an algorithmic perspective*. [S.l.]: CRC press, 2015.
- [55] HOSMER, D.; LEMESHOW, S. *Applied Logistic Regression*. [S.l.]: Wiley, 2004. (Applied Logistic Regression). ISBN 9780471654025.
- [56] KURT, I.; TURE, M.; KURUM, A. T. Comparing performances of logistic regression, classification and regression tree, and neural networks for predicting coronary artery disease. *Expert Systems with Applications*, v. 34, n. 1, p. 366 – 374, 2008. ISSN 0957-4174.
- [57] BARBON, A. P. A. et al. Storage time prediction of pork by computational intelligence. *Computers and Electronics in Agriculture*, v. 127, p. 368 – 375, 2016. ISSN 0168-1699.
- [58] QUINLAN, J. R. Improved use of continuous attributes in c4.5. *J. Artif. Int. Res.*, AI Access Foundation, USA, v. 4, n. 1, p. 77–90, mar. 1996. ISSN 1076-9757.
- [59] YADAV, A. K.; CHANDEL, S. Solar energy potential assessment of western himalayan indian state of himachal pradesh using {J48} algorithm of {WEKA} in {ANN} based prediction model. *Renewable Energy*, v. 75, p. 675 – 693, 2015. ISSN 0960-1481.
- [60] MITCHELL, T. M. *Machine learning*. New York, 1997.
- [61] BALAMURUGAN, A. alias et al. Nb+: An improved naïve bayesian algorithm. *Knowledge-Based Systems*, v. 24, n. 5, p. 563 – 569, 2011. ISSN 0950-7051.
- [62] BREIMAN, L. Random forests. *Machine Learning*, v. 45, n. 1, p. 5–32, 2001. ISSN 1573-0565.
- [63] RIPLEY, B. D. *Pattern recognition and neural networks*. [S.l.]: Cambridge university press, 2007.
- [64] VAPNIK, V. N. *The Nature of Statistical Learning Theory*. New York, NY, USA: Springer-Verlag New York, Inc., 1995. ISBN 0-387-94559-8.
- [65] BEN-HUR, A.; WESTON, J. A user's guide to support vector machines. *Data mining techniques for the life sciences*, Springer, p. 223–239, 2010.

- [66] VILALTA, R.; GIRAUD-CARRIER, C.; BRAZDIL, P. Meta-learning - concepts and techniques. In: _____. *Data Mining and Knowledge Discovery Handbook*. Boston, MA: Springer US, 2010. p. 717–731. ISBN 978-0-387-09823-4.
- [67] LANDSAT on AWS. <<https://aws.amazon.com/public-data-sets/landsat/>>. Accessed: 2016-03-14.
- [68] BALAJI, G.; SUBASHINI, T.; CHIDAMBARAM, N. Automatic classification of cardiac views in echocardiogram using histogram and statistical features. *Procedia Computer Science*, v. 46, n. 0, p. 1569–1576, 2015. ISSN 1877-0509. Proceedings of the International Conference on Information and Communication Technologies, {ICICT} 2014, 3-5 December 2014 at Bolgatty Palace Camp; Island Resort, Kochi, India.
- [69] YEGANEH, H.; WANG, Z. Objective quality assessment of tone-mapped images. *IEEE Transactions on Image Processing*, v. 22, n. 2, p. 657–667, Feb 2013. ISSN 1057-7149.
- [70] CHOWDHURY, S.; VERMA, B.; STOCKWELL, D. A novel texture feature based multiple classifier technique for roadside vegetation classification. *Expert Systems with Applications*, v. 42, n. 12, p. 5047–5055, 2015. ISSN 0957-4174.
- [71] SHEN, H.-K.; CHEN, P.-H.; CHANG, L.-M. Automated steel bridge coating rust defect recognition method based on color and texture feature. *Automation in Construction*, v. 31, n. 0, p. 338–356, 2013. ISSN 0926-5805.
- [72] MONTANES, E. et al. Dependent binary relevance models for multi-label classification. *Pattern Recognition*, v. 47, n. 3, p. 1494 – 1508, 2014. ISSN 0031-3203.
- [73] RODRIGUEZ-GALIANO, V. et al. An assessment of the effectiveness of a random forest classifier for land-cover classification. *{ISPRS} Journal of Photogrammetry and Remote Sensing*, v. 67, p. 93 – 104, 2012. ISSN 0924-2716.

TRABALHOS PUBLICADOS PELO AUTOR

Trabalhos publicados pelo autor durante o programa.

1. Barbin, D.F.; Mastelini, S.M.; Barbon, S.; Campos, G.F.C.; Barbon, A.P.A.C.; Shimokomaki, M., **Digital image analyses as an alternative tool for chicken quality assessment**, Biosystems Engineering, 2016, Elsevier, (Qualis ENG-IV 2014, B2)
2. Campos, G.F.C.; Mantovani, R. G.; Barbon, S., **A Meta-learning Approach for Recommendation of Image Segmentation Algorithms**, Conference on Graphics, Patterns and Images (SIBGRAPI), 2016, SBC, (Qualis CC 2012, B1)
3. Campos, G.F.C.; Igawa, R.A.; Seixas, J.L.; Almeida, A.M.G.; Guido, R.C.; Barbon, S., **Supervised Approach for Indication of Contrast Enhancement in Application of Image Segmentation**, International Conference on Advances in Multimedia (MMEDIA), 2016, IARIA, (Qualis CC 2012, B4)