

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL**  
**ESCOLA DE ENGENHARIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO**

**Fábio do Prado Puglia**

**ABORDAGENS DE CLASSIFICAÇÃO E  
INTERPRETAÇÃO EM ANÁLISE DE  
IMAGENS PARA CONTROLE DE  
QUALIDADE**

Porto Alegre

2021

Fábio do Prado Puglia

**Abordagens de classificação e interpretação em análise de imagens para controle de  
qualidade**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul como requisito parcial à obtenção do título de Mestre em Engenharia de Produção, modalidade Acadêmica, na área de concentração em Sistemas de Qualidade.

Orientador: Michel José Anzanello, *Ph.D.*

Porto Alegre

2021

Fábio do Prado Puglia

**Abordagens de classificação e interpretação em análise de imagens para controle de qualidade**

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia de Produção na modalidade Acadêmica e aprovada em sua forma final pelo Orientador e pela Banca Examinadora designada pelo Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul.

---

**Prof. Michel José Anzanello, *Ph.D.***

Orientador PPGEP/UFRGS

---

**Prof. Alejandro Germán Frank. *Dr.***

Coordenador PPGEP/UFRGS

**Banca Examinadora:**

Professora Miriam Rocha, Dr. (PPGA/UFERSA)

Professor Alessandro Kahmann, Dr. (IMEF/FURG)

Professor Marcelo Farenzena, Dr. (PPGEQ/UFRGS)

PUGLIA, Fábio do Prado *Abordagens de classificação e interpretação em análise de imagens para controle de qualidade*, 2021. Dissertação (Mestrado em Engenharia) - Universidade Federal do Rio Grande do Sul, Brasil.

## RESUMO

A presente dissertação propõe métodos para classificação e interpretação em análise de imagens no contexto de controle de qualidade e autenticidade de produtos. O trabalho é composto por três artigos. Inicialmente, uma revisão bibliográfica sobre métodos de seleção de variáveis em análises de imagens fornece uma visão inicial sobre o assunto. No segundo artigo, propõe-se uma sistemática para detecção de medicamentos falsificados com base em imagens de comprimidos, bem como para identificação das regiões dos comprimidos mais relevantes para a tarefa de classificação. A aplicação do método em dois bancos de dados resultou em desempenhos de classificação de 100% na porção de teste, e a comparação com um método reportado na literatura como referência na interpretação de imagens mostrou que a abordagem proposta é superior em termos de robustez. O terceiro artigo propõe uma abordagem hierárquica para classificação de qualidade de carne a partir de imagens de contrafilé bovino. O método combina dois classificadores em uma abordagem de natureza hierárquica na qual a ordem de utilização dos classificadores é determinada pela acurácia dos mesmos. A sistemática foi validada em seis diferentes conjuntos de dados com acurácia de 90% ou mais elevada, e desempenho superior ao gerado pela abordagem de referência ao avaliarem-se métricas de desempenho de classificação como acurácia, sensibilidade e especificidade.

**Palavras-chave:** análise de imagens, aprendizado supervisionado, classificação, interpretação.

PUGLIA, Fábio do Prado *Classification and interpretation approaches in image analysis for quality control*, 2021. Dissertação (Mestrado em Engenharia) - Universidade Federal do Rio Grande do Sul, Brasil.

### **ABSTRACT**

This dissertation proposes methods for classification and interpretation in image analysis in the context of product quality control and authenticity. The work consists of three articles. Initially, a literature review on feature selection methods in image analysis provides an initial view on the subject. In the second article, a system for the detection of counterfeit medicines based on tablet images is proposed, as well as for the identification of the most relevant tablet regions in the classification task. Validation of the method in two databases resulted in classification performances of 100% in the test portion, and the comparison with a method reported in the literature as a reference in image interpretation showed that the proposed approach is superior in robustness. The third article proposes a hierarchical approach to classify meat quality based on beef images. The method combines two classifiers in a hierarchical approach in which the order in each the classifiers are applied is determined by their respective accuracy. The systematic was validated in six different datasets with accuracy 90% or higher, and performance superior to the one generated by the reference approach when assessing accuracy, sensitivity and specificity.

**Keywords:** image analysis, supervised learning, classification, interpretability.

## LISTA DE FIGURAS

Figura 2.1 – Combinação de termos para busca.....	22
Figura 2.2 – Diagrama resumindo o fluxo de seleção de artigos.....	24
Figura 2.3 – Abordagens de seleção de variáveis agrupadas por tipo de aplicação e técnica....	35
Figura 3.1 – <i>Preprocessing step</i> .....	53
Figura 3.2 – <i>Explanation of systematic prediction provided by proposed method for Cialis</i> .....	54
Figura 3.3 – <i>Explanation of systematic prediction provided by proposed method for Viagra</i> ...	55
Figura 3.4 – <i>Explanations for individual predictions provided by LIME for the Cialis dataset</i> ...	56
Figura 4.1 – Imagens das amostras de contrafilés.....	64
Figura 4.2 – Estrutura da abordagem proposta.....	67
Figura 4.3 – Comparação de cores no contrafilé para as classes ‘adequada’ e ‘não-adequada’..	74

## LISTA DE TABELAS

Tabela 1.1 – Sumarização dos artigos apresentados na dissertação.....	17
Tabela 3.1 – <i>Results for subregion and image classification</i> .....	52
Tabela 4.1 – Subconjuntos de variáveis gerados com RF-RFE.....	73
Tabela 4.2 – Desempenho da abordagem proposta para a tarefa de classificação.....	75
Tabela 4.3 – Pares de classificadores com melhores desempenhos.....	75
Tabela 4.4 – Desempenhos da abordagem de Bernart <i>et al.</i> (2016) e abordagem proposta.....	76

## LISTA DE SIGLAS

ABC	<i>Artificial Bee Colony</i>
ANN	<i>Artificial Neural Network</i>
BFS	<i>Backward Feature Selection</i>
CARS	<i>Competitive Adaptive Reweighted Sampling</i>
CART	<i>Classification And Regression Trees</i>
CFS	<i>Correlation-based feature selection</i>
CMIM	<i>Conditional Mutual Information Maximization</i>
DA	<i>Discriminant Analysis</i>
DT	<i>Decision Trees</i>
ESI-MS	<i>Electrospray Ionization Mass Spectrometry</i>
FFS	<i>Forward Feature Selection</i>
GA	<i>Genetic Algorithm</i>
HSI	<i>Hue, Saturation, Intensity</i>
iPLS	<i>Interval Partial Least Squares</i>
KNN	<i>K-Nearest Neighbors</i>
LDA	<i>Linear Discriminant Analysis</i>
LR	<i>Logistic Regression</i>
LIME	<i>Local Interpretable Model-agnostic Explanations</i>
MI	<i>Mutual Information</i>
mRMR	<i>Minimum Redundancy Maximum Relevance</i>
NB	<i>naive Bayes</i>
NIR	<i>Near Infrared</i>
OSP	<i>Orthogonal Subspace Projection</i>
PCA	<i>Principal Component Analysis</i>
PLS	<i>Partial Least Squares</i>
PVC	<i>Policloreto de Vinila</i>
QDA	<i>Quadratic Discriminant Analysis</i>
RF	<i>Random Forest</i>
RFE	<i>Recursive Feature Elimination</i>
RF-RFE	<i>Random Forest-Recursive Feature Elimination</i>
RGB	<i>Red, Green, Blue</i>
SBFS	<i>Sequential Backward Feature Selection</i>
SFBFS	<i>Sequential Floating Backward Feature Selection</i>
SFFFS	<i>Sequential Floating Forward Feature Selection</i>
SFFS	<i>Sequential Forward Feature Selection</i>
SLIC	<i>Simple Linear Iterative Clustering</i>
SPA	<i>Sucesive Projection Algorithm</i>
sPCA	<i>Sparse Principal Component Analysis</i>
sPLS	<i>Sparse Partial Least Squares</i>
SVM	<i>Support Vector Machine</i>
VIP	<i>Variable Importance in Projection</i>

## SUMÁRIO

RESUMO .....	4
ABSTRACT .....	5
LISTA DE FIGURAS .....	6
LISTA DE TABELAS .....	7
<b>1 Introdução .....</b>	<b>11</b>
<b>1.1 Considerações Iniciais .....</b>	<b>11</b>
<b>1.2 Objetivos.....</b>	<b>12</b>
<b>1.3 Justificativa do Tema e dos Objetivos .....</b>	<b>13</b>
<b>1.4 Procedimentos Metodológicos .....</b>	<b>14</b>
<b>1.5 Delimitações do Estudo .....</b>	<b>15</b>
<b>1.6 Estrutura da Dissertação .....</b>	<b>16</b>
<b>1.7 Referências Bibliográficas .....</b>	<b>17</b>
<b>2. Primeiro artigo: Métodos de seleção de variáveis em análise de imagens para aplicações alimentícias .....</b>	<b>19</b>
<b>2.1 Introdução .....</b>	<b>20</b>
<b>2.2 Método .....</b>	<b>21</b>
<b>2.3 Descrição .....</b>	<b>24</b>
<b>2.3.1 Métodos tipo Filter.....</b>	<b>25</b>
<b>2.3.2 Métodos tipo Wrapper.....</b>	<b>29</b>
<b>2.4 Análise e Discussão .....</b>	<b>33</b>
<b>2.5 Conclusão .....</b>	<b>37</b>
<b>2.6 Referências .....</b>	<b>38</b>
<b>3 Segundo Artigo: A novel approach for the identification of most relevant tablet regions in the image detection of falsified medicines.....</b>	<b>44</b>
<b>3.1 Introduction .....</b>	<b>44</b>
<b>3.2 Materials and methods.....</b>	<b>47</b>
<b>3.2.1 Dataset.....</b>	<b>47</b>
<b>3.2.2 Proposed framework.....</b>	<b>48</b>
3.2.2.1 Image preprocessing according to Bernart <i>et al.</i> (2016).....	48
3.2.2.1.1 Background removal .....	48

3.2.2.1.2 Pixel clustering .....	49
3.2.2.1.3 Feature extraction .....	49
3.2.2.2 Classification of authentic and falsified tablets .....	50
3.2.2.3 Identification of the most relevant tablet regions for classification.....	51
<b>3.3 Results.....</b>	<b>51</b>
<b>3.4 Conclusions .....</b>	<b>56</b>
<b>3.5 References .....</b>	<b>57</b>
<b>4 Terceiro Artigo: Avaliação da qualidade de carne embalada apoiada em análise de imagens e ferramentas multivariadas .....</b>	<b>60</b>
<b>4.1 Introdução.....</b>	<b>61</b>
<b>4.2. Materiais e Métodos .....</b>	<b>63</b>
<b>4.2.1 Dados.....</b>	<b>63</b>
<b>4.2.2 Fundamentação teórica das técnicas multivariadas de classificação .....</b>	<b>65</b>
4.2.2.1 SVM.....	65
4.2.2.2 RF.....	65
4.2.2.3 KNN.....	66
<b>4.2.3 Abordagem proposta.....</b>	<b>66</b>
4.2.3.1 Pré-processamento de imagem.....	67
4.2.3.1.1 Remoção do fundo e identificação de região de interesse.....	67
4.2.3.1.2 Agrupamento de pixels.....	69
4.2.3.1.3 Extração de variáveis.....	70
4.2.3.2 Abordagem proposta para classificação hierárquica.....	70
<b>4.3. Resultados e Discussões.....</b>	<b>72</b>
<b>4.4 Conclusões .....</b>	<b>76</b>
<b>4.5 Referências .....</b>	<b>77</b>
<b>5 Considerações finais.....</b>	<b>80</b>
<b>5.1 Conclusões.....</b>	<b>80</b>
<b>5.2 Sugestões para trabalhos futuros.....</b>	<b>81</b>

## 1 Introdução

### 1.1 Considerações Iniciais

O processo de globalização de mercados e a consequente exposição da indústria e produtores a um ambiente com maior competitividade aumentam a relevância da qualidade percebida de produtos oferecidos ao consumidor (ERNST; HAAR, 2019). Para garantir altos padrões de qualidade, os agentes envolvidos necessitam ter acesso a informações confiáveis sobre a qualidade dos produtos (DAMEZ; CLERJON, 2013). Em uma ampla variedade de aplicações e segmentos, o controle e a garantia da qualidade são conduzidos de forma manual, através de análises químicas ou métodos mecânicos, o que faz com que o processo seja demorado, destrutivo ou custoso (ELMASRY; NAKAUCHI, 2016). Nestas circunstâncias, acentua-se a necessidade de adoção de procedimentos objetivos, rápidos e não destrutivos, como técnicas automáticas baseadas em análise de imagens derivadas do produto em questão.

Métodos de análise de imagem combinam um sistema de captura de imagens com técnicas de aprendizado, de forma a simular artificialmente o processo humano de avaliação de cor, forma e textura (DU; SUN, 2006). Apoiada em métodos de aprendizado de máquina, a abordagem permite a automatização de processos decisórios com precisão e de forma rápida e consistente. Além da etapa de aprendizado de máquina, sistemáticas de análise de imagem geralmente incluem etapas iniciais de pré-processamento, como tratamento de ruído, identificação de região de interesse e segmentação da imagem (PATEL *et al.*, 2012).

Diversos autores empregaram análise de imagem com o intuito de detectar ou controlar aspectos referentes à qualidade. No contexto de aplicações alimentícias, imagens foram exploradas como meio de investigar diferentes naturezas de objetos de interesse, como frutas, vegetais, grãos, queijo e carne, entre outros (PATEL *et al.*, 2012). No contexto forense, uma das principais aplicações refere-se à investigação de medicamentos falsificados, como fizeram Jung *et al.* (2012) e Al Hagbani *et al.* (2017).

Com base neste cenário, o presente trabalho propõe abordagens para classificação e explicação de predições de imagens em aplicações voltadas ao controle de qualidade e detecção de falsificações de produtos alimentícios e farmacêuticos. A dissertação é composta por três artigos dedicados à tarefa de detecção de imagens. O primeiro conduz uma revisão bibliográfica dos métodos de seleção de variáveis no contexto de detecção de alimentos através de imagens, ao

mesmo tempo em que destaca as diferentes técnicas utilizadas nos respectivos estudos para os propósitos de classificação e regressão. O segundo artigo propõe uma sistemática para detecção de medicamentos falsificados e identificação das regiões dos comprimidos mais relevantes na etapa de classificação das amostras em autênticas ou adulteradas. O método para explicação de predições baseia-se no conceito dos vetores de suporte, inerente ao classificador *Support Vector Machine* (SVM). O desempenho da abordagem proposta foi validado em dois bancos de dados de medicamentos, e comparado com uma abordagem referência na literatura. O terceiro artigo propõe uma abordagem de classificação hierárquica para a identificação da qualidade de carne bovina com base em seu tempo de permanência em prateleira com base em imagens. A sistemática é validada em seis conjuntos de dados, e os resultados são comparados com uma abordagem de referência.

## 1.2 Objetivos

O objetivo principal da dissertação é a proposição de novas abordagens para combinação de visão computacional e aprendizado de máquina em aplicações para identificação de falsificações no contexto forense e predição de qualidade de produtos alimentícios. Como objetivos específicos, são apresentados:

- Investigar as principais técnicas de seleção de variáveis utilizadas em combinação com análise de imagens, com foco na contribuição para o processo de detecção de variações nas características de qualidade de alimentos;
- Identificar oportunidades de novas combinações de métodos de seleção de variáveis e aplicações no contexto de detecção de alimentos;
- Identificar as regiões visualmente relevantes na tarefa de classificação de medicamentos falsificados;
- Comparar o desempenho da abordagem proposta para identificação das regiões relevantes com desempenho da abordagem de referência apontada pela literatura; e
- Comparar os desempenhos das abordagens para avaliação de qualidade e detecção de falsificações com os desempenhos das abordagens de referência reportadas na literatura.

### 1.3 Justificativa do Tema e dos Objetivos

Os mercados de produção de alimentos e de medicamentos estão na lista dos mais importantes globalmente, em termos de volume financeiro (BELLONI *et al.*, 2016; SCHNEIDER *et al.*, 2011). Enquanto o mercado de alimentos enfrenta desafios para mensurar e garantir a qualidade dos produtos, a indústria de medicamentos é vítima de crimes de falsificação de seus produtos, especialmente os que apresentam elevado valor agregado ou são de difícil obtenção. Para os dois casos, uma solução promissora é a adoção de técnicas analíticas para identificação da qualidade e autenticidade dos produtos (DAMEZ; CLERJON, 2013; DÉGARDIN *et al.*, 2014).

Entre as principais técnicas utilizadas para controle de qualidade, destacam-se as apoiadas na exploração de espectroscopia do infravermelho e imagens hiperespectrais (DOS SANTOS *et al.*, 2019). Porém, enquanto a primeira falha na tarefa de fornecer informações espaciais sobre o objeto estudado, a segunda apresenta como desvantagem as etapas de aquisição e análise das imagens, por serem mais demoradas e custosas, em comparação ao que ocorre com imagens no espectro visível (ELMASRY; NAKAUCHI, 2016; NAKAUCHI *et al.*, 2012). Além disso, o elevado número de variáveis espectrais gerados na espectroscopia pode comprometer o desempenho preditivo de várias técnicas multivariadas, além de reduzir a interpretabilidade do modelo (SOARES; ANZANELLO, 2017).

Análises de imagens no espectro visível apresentam-se como uma solução a esta problemática, pela facilidade de operacionalização, reduzido custo na obtenção das imagens (que podem ser feitas através de câmeras comuns) e alto desempenho (JUNG *et al.*, 2011). A abordagem tem se mostrado útil em diversas aplicações relacionadas ao controle de qualidade no contexto de alimentos, e seu emprego é viabilizado pelo desenvolvimento da capacidade computacional e velocidade de processamento de algoritmos de análise de imagens (WANG; SUN, 2001). Entre as principais vantagens associadas à sistemática de análise de imagens, destacam-se a capacidade de inspecionar os objetos de interesse de forma automática, objetiva, rápida e higiênica (BROSNAN; SUN, 2004).

Enquanto o desempenho de predição de classificadores recebe destaque na quase totalidade de trabalhos em abordagens de aprendizado supervisionado, a interpretabilidade dos classificadores nem sempre figura nas discussões dos estudos. Entretanto, tal aspecto deve ser

valorizado na construção de um classificador tendo em vista que facilita a compreensão do mesmo por parte do usuário, o que aumenta as chances do algoritmo ser aceito e, suas predições, aproveitadas em aspectos práticos (VELLIDO *et al.*, 2012; CHAKRABORTY *et al.*, 2017). Além disso, a compreensão da forma de funcionamento de um modelo permite a identificação de vieses indesejados, levando ao aprimoramento do algoritmo e sua adaptação a propósitos específicos (GUNNING *et al.*, 2019).

#### 1.4 Procedimentos Metodológicos

Em relação à tipologia, a presente dissertação pode ser classificada como pesquisa de natureza aplicada, com fins exploratórios e abordagem quantitativa. Caracteriza-se como natureza aplicada por apresentar ênfase prática na solução de problemas específicos. Apresenta caráter exploratório por ser desenvolvida de forma a proporcionar uma visão geral acerca dos fenômenos estudados, além de conduzir levantamento bibliográfico. Por fim, adota abordagem quantitativa por fazer utilização de métodos de aprendizado de máquina, analisando os fatos a partir de quantificações e gerando generalizações dos resultados encontrados (GIL, 2002).

O primeiro artigo da dissertação conduz uma pesquisa bibliográfica sobre métodos de seleção de variáveis aplicados em análise de detecção de alimentos. O estudo apresenta uma visão geral sobre o assunto, organizando os artigos em três dimensões: tipo de método de seleção de variáveis (*filter* ou *wrapper*), técnica empregada na análise (as técnicas foram agrupadas conforme semelhança dos conceitos envolvidos), e tipo de aplicação (conforme objeto de interesse envolvido na análise).

O segundo artigo emprega análise de imagens para a detecção de medicamentos falsificados e identificação das regiões dos comprimidos mais relevantes para sua classificação em autênticos ou falsificados. Numa etapa inicial de pré-processamento das imagens, a região do comprimido é separada do fundo, os pixels desta região são agrupados em sub-regiões, e variáveis com informações de cor e textura são extraídas para cada sub-região. Na sequência, promove-se a classificação de cada sub-região através do classificador SVM, e a classe predita para cada imagem é determinada pelo cálculo da proporção de sub-regiões atribuídas a cada classe. A tarefa de identificação de sub-regiões mais relevantes para a classificação apoia-se na estrutura fundamental do classificador SVM, utilizando o conceito de vetores de suportes

(*support vectors*). O resultado desta etapa é um mapa de calor, o qual identifica visualmente a contribuição proporcional de cada região na detecção de falsificações. A abordagem proposta foi validada em dois conjuntos de medicamentos, e os resultados foram comparados com os obtidos pelo método LIME (Ribeiro *et al.*, 2016).

No terceiro artigo, conduziu-se a tarefa de identificação da qualidade de contrafilés bovinos com base em dados do tipo imagem. A percepção de qualidade está associada ao aspecto da carne embalada, a qual tende a mudar de cor devido ao tempo de permanência da amostra em prateleiras de estabelecimentos comerciais. Para tanto, foi proposta uma abordagem de classificação hierárquica alimentada por imagens pré-processadas. A etapa de pré-processamento identifica a região de interesse que delimita os contornos da amostra de carne, agrupa os pixels em entidades denominadas superpixels, e computa variáveis com informações de cor e textura. A classificação dos superpixels ocorre pela combinação hierárquica de pares de classificadores. A determinação da ordem de aplicação dos classificadores, e de quais subconjuntos de observações são utilizados para cada classificador, é função da taxa da acurácia dos classificadores. Ao final, a classe de cada imagem é calculada de acordo com a proporção das sub-regiões pertencentes à imagem atribuídas a cada classe. A validação do método proposto foi feita pela sua aplicação em seis conjuntos de imagens de contrafilé bovino, de diferentes tipos de animais e embalagens de policloreto de vinila (PVC) ou a vácuo. O desempenho da abordagem proposta foi comparado com o obtido pela proposição de Bernart *et al.* (2016).

## 1.5 Delimitações do Estudo

O escopo do presente trabalho delimita-se pela utilização de dados de imagem como objeto de interesse. Esta restrição é válida tanto para os artigos investigados na literatura quanto para as abordagens propostas. Além disso, as sistemáticas propostas envolvem apenas imagens no espectro visível, não considerando imagens originadas nos demais espectros, como infravermelho, ou imagens hiperespectrais.

As proposições apresentadas não envolvem novas ferramentas para obtenção ou pré-processamento de imagens, restringindo-se a propor apenas novas ferramentas para a tarefa de classificação dos dados extraídos de imagens. Nas sistemáticas de detecção de qualidade de alimento e identificação de falsificações de medicamentos, são utilizadas apenas abordagens de

classificação, não sendo explorados métodos com o objetivo de regressão ou com objetivos exploratórios (clusterização).

## **1.6 Estrutura da Dissertação**

A dissertação está organizada em cinco capítulos, dos quais o primeiro introduz o trabalho, apresentando os objetivos e justificativas, descrevendo os métodos explorados e definindo a estrutura do trabalho. O capítulo finaliza com a definição da delimitação do estudo.

O segundo capítulo apresenta o primeiro artigo, o qual conduz uma revisão bibliográfica dos métodos de seleção de variáveis empregados em detecção de alimentos. O capítulo apresenta uma visão geral de técnicas de aprendizado de máquina utilizadas em aplicações de análise de imagens, uma vez que, além de avaliar as técnicas de seleção de variáveis empregadas no contexto, destaca as técnicas preditivas utilizadas para os propósitos de classificação e regressão.

No terceiro capítulo, apresenta-se o artigo que emprega análise de imagens para detecção de medicamentos falsificados, segundo artigo do trabalho. Além da tarefa de classificação, o artigo identifica as regiões que visualmente mais contribuem para a identificação de falsificações. A abordagem proposta é verificada em dois conjuntos de dados contendo imagens de medicamentos autênticos e falsificados. O método proposto é comparado com uma abordagem de referência.

O quarto capítulo traz o terceiro artigo, referente à identificação de qualidade de carne bovina a partir de imagens de contrafilé. O artigo propõe uma nova abordagem hierárquica, a qual combina diferentes classificadores de acordo com a acurácia de predição dos mesmos. A abordagem proposta é validada em seis bases de dados contendo tipos de animais e formas de embalagens diferentes, e os desempenhos são comparados com os obtidos na abordagem de referência.

O último capítulo apresenta a conclusão do trabalho, resgatando os objetivos iniciais e conectando-os aos principais resultados obtidos. O trabalho é encerrado com a proposição de desdobramentos futuros. A Tabela 1.1 apresenta uma sumarização dos artigos que compõem a dissertação.

Tabela 1.1 – Sumarização dos artigos apresentados na dissertação

<b>Artigo</b>	<b>Contribuições</b>	<b>Método</b>
Métodos de seleção de variáveis em análise de imagens para aplicações alimentícias	- Investigar técnicas de seleção de variáveis em análise de imagens para aplicações alimentícias; - Identificar oportunidades de combinações entre técnicas e aplicações	Revisão bibliográfica
A novel approach for the identification of most relevant tablet regions in the image detection of falsified medicines	- Detecção de medicamentos falsificados; - Identificação das regiões relevantes na tarefa de classificação	Abordagem de classificação para detecção de falsificações e mapa de calor para identificação das regiões relevantes
Avaliação da qualidade de carne embalada apoiada em análise de imagens e ferramentas multivariadas	- Identificação do estado de conservação de contrafilés bovinos ('adequado' ou 'não-adequado')	Abordagem hierárquica para classificação da qualidade embalada com base em imagens

## 1.7 Referências Bibliográficas

AL HAGBANI, T. et al. Can the surface color of pharmaceutical tablets be used as a unique product identifier? **Journal of Drug Delivery Science and Technology**, v. 37, p. 141-146, 2017.

BELLONI, A.; MORGAN D.; PARIS, V. Pharmaceutical Expenditure And Policies: Past Trends And Future Challenges. **OECD Health Working Papers**, v. 87, OECD Publishing, Paris, 2016.

BERNART, E.; SCHARCANSKI, J.; BAMPI, S. Segmentation and Classification of Melanocytic Skin Lesions Using Local and Contextual Features. **IEEE International Conference on Image Processing (ICIP)**. IEEE, 2016.

BROSNAN, T; SUN, D. W. Improving quality inspection of food products by computer vision—a review. **Journal of food engineering**, v. 61, n. 1, p. 3-16, 2004.

CHAKRABORTY, S. et al. Interpretability of deep learning models: a survey of results. **smartworld/SCALCOM/UIC/ATC/CBDcom/IOP/SCI** pp. 1-6. IEEE, ago. 2017.

DAMEZ, J. L.; CLERJON, S. Quantifying and predicting meat and meat products quality attributes using electromagnetic waves: An overview. **Meat science** v.95, n. 4, p. 879-896, 2013.

DÉGARDIN, K.; ROGGO, Y.; MARGOT, P. Understanding and fighting the medicine counterfeit market. **Journal of pharmaceutical and biomedical analysis** v. 87, p. 167-175, 2014

DOS SANTOS, M. et al. Comparison between counterfeit and authentic medicines: a novel approach using Differential Scanning Calorimetry and Hierarchical Cluster Analysis. **Journal of Pharmaceutical and Biomedical Analysis**, 2019.

DU, C. J.; SUN, D. W. Learning techniques used in computer vision for food quality evaluation: a review. **Journal of food engineering** v. 72, n. 1, p. 39-55, 2006.

ELMASRY, G. M.; NAKAUCHI, S. Image analysis operations applied to hyperspectral images for non-invasive sensing of food quality—a comprehensive review. **Biosystems engineering** v. 142, p. 53-82, 2016.

ERNST, R.; HAAR, J. (2019) Competitiveness. In: Globalization, Competitiveness, and Governability. Palgrave Macmillan, Cham.

GIL, A. C. **Como elaborar projetos de pesquisa**. Vol. 4. São Paulo: Atlas, 2002.

GUNNING, D. et al. XAI—Explainable artificial intelligence. **Science robotics**, dez 2019.

JUNG, C. R. et al. A new methodology for detection of counterfeit Viagra® and Cialis® tablets by image processing and statistical analysis. **Forensic science international**, v. 216, n. 1-3, p. 92-96, 2012.

NAKAUCHI, S., NISHINO K.; YAMASHITA, T. Selection of optimal combinations of band-pass filters for ice detection by hyperspectral imaging. **Optics express**, v. 20, n. 2, p. 986-1000, 2012.

PATEL, K. K. et al. Machine vision system: a tool for quality inspection of food and agricultural products. **Journal of food science and technology**, v. 49, n. 2, p. 123-141, 2012.

RIBEIRO, M.; SINGH, S.; GUESTRIN, C. Model-Agnostic Interpretability of Machine Learning. **arXiv preprint arXiv:1606.05386**, 2016.

SCHNEIDER, U. A. et al. Impacts of population growth, economic development, and technical change on global food production and consumption. **Agricultural Systems**, v. 104, n. 2, p. 204-215, 2011.

SOARES, F.; ANZANELLO, M. Support vector regression coupled with wavelength selection as a robust analytical method. **Chemometrics and Intelligent Laboratory Systems**, v. 172, 2017.

VELLIDO, A.; MARTÍN-GUERRERO, J. D.; LISBOA, P. J. G. Making machine learning models interpretable. **ESANN**, v. 12, 2012.

WANG, H. H.; SUN, D. W. Evaluation of the functional properties of cheddar cheese using a computer vision method. **Journal of Food Engineering**, v. 49, n. 1, p. 49-53, 2001.

## 2. Primeiro artigo: Métodos de seleção de variáveis em análise de imagens para aplicações alimentícias

**Fábio do Prado Puglia**

**Michel José Anzanello**

### **Resumo**

A dificuldade em eliminar o problema da fome em países em desenvolvimento estimula pesquisadores a desenvolverem métodos computacionais para monitorar e detectar a qualidade dos alimentos nos processos de produção. Uma ferramenta relevante neste contexto é a seleção de variáveis. Neste artigo, é apresentada uma revisão de literatura referente aos métodos de seleção de variáveis utilizados na detecção de alimentos através de imagens. Os métodos são organizados em dois grandes grupos: métodos de seleção de variáveis do tipo *filter* e *wrapper*. Além da identificação dos principais métodos utilizados, são apontadas oportunidades de novas combinações entre métodos e tipos de aplicações.

**Palavras-chave:** seleção de variáveis, *filter*, *wrapper*, detecção, alimentos, imagem.

### **Methods for selecting variables in image analysis for food applications**

#### **Abstract**

The difficulty in eliminating hunger in developing countries encourages researchers to develop computational methods to monitor and detect the quality of food in production processes. A relevant tool in this context is feature selection. In this article, a literature review is presented regarding the methods of feature selection used to detect food through images. The methods are organized into two large groups: filter and wrapper. In addition to identifying the main methods used, opportunities for new combinations of methods and application types are pointed out.

**Keywords:** feature selection, filter, wrapper, detection, food, image.

## 2.1 Introdução

Fome e pobreza continuam sendo grandes problemas em países em desenvolvimento, como o Brasil, sendo agravados pelos recentes aumentos nos preços dos alimentos. Uma forma de combater estes problemas é através do aumento na produtividade de alimentos e redução de perdas. Dados mostram que entre um terço e metade da produção de alimentos é perdida no processo relacionado à colheita (FLOOD, 2010). Uma agricultura sustentável e com baixo nível de perdas pode ser alcançada pela adoção de métodos de monitoramento da qualidade de plantas e frutas, visando à identificação precoce de doenças nos alimentos (KHAN *et al.*, 2018). Tradicionalmente, a forma de se monitorar e identificar doenças em plantas envolve atuação direta humana, geralmente de um especialista que conduz a inspeção visual. Esta abordagem, além de ser altamente custosa e demorada, muitas vezes só permite a identificação do problema quando a implementação de medidas de combate já não é mais possível. Como proposta alternativa, métodos automáticos e inteligentes para detecção de plantas e identificação de doenças, baseados em processamento de imagens e algoritmos computacionais, fornecem soluções rápidas e eficientes, dispensando o envolvimento humano direto (KHAN *et al.*, 2018).

A abordagem computacional para detecção de alimentos via imagem envolve geralmente quatro principais etapas: pré-processamento, extração de variáveis, seleção de variáveis e predição. Porém, esta estratégia apresenta suas desvantagens. A utilização de imagens de alta resolução impõe o desafio do desenvolvimento e adoção de técnicas adequadas para o tratamento de grandes volumes de dados (JOVIĆ *et al.*, 2015). Diversos algoritmos de predição têm seu desempenho dependente das propriedades dos dados aos quais são aplicados. Além disso, dependendo da aplicação, deseja-se que o modelo seja explicativo e interpretável. Em tais casos, é interessante que o modelo final seja composto de poucas variáveis explicativas, mas que as mesmas sejam relevantes para o algoritmo em questão. Neste contexto, a seleção de variáveis se caracteriza como um dos principais desafios em aplicações de visão computacional (GAUCHI *et al.*, 2001; KHAN *et al.*, 2018).

O processo de seleção de variáveis pode ser definido como redução da dimensionalidade através da seleção de um subconjunto de variáveis, removendo variáveis redundantes ou irrelevantes do conjunto de dados original (KARABULUT *et al.*, 2012; TAN *et al.*, 2016). A abordagem ideal consiste em testar todos os subconjuntos possíveis de variáveis como insumos

para o algoritmo de interesse e manter o subconjunto que apresentar melhor resultado. Porém, como o número de possíveis combinações em um conjunto com  $N$  variáveis é  $(2^N - 1)$ , esta abordagem se torna impraticável para a maioria dos casos (TAN *et al.*, 2016). De forma geral, o processo de seleção de variáveis consiste em quatro etapas: (i) geração de um subconjunto de variáveis, (ii) avaliação do subconjunto, (iii) critério de parada e (iv) validação dos resultados (JOVIĆ *et al.*, 2015). O principal objetivo da seleção de variáveis é o aumento do desempenho do algoritmo, seja em relação ao tempo de processamento, capacidade de generalização ou simplicidade de representação (MOLINA *et al.*, 2002).

Tendo em vista a grande variedade de métodos disponíveis para esta tarefa, é difícil fazer a escolha do método adequado para cada tipo de dado e problema (XIAOBO *et al.*, 2010). Para contornar este problema, o presente artigo propõe-se a responder à seguinte questão de pesquisa: quais métodos de seleção de variáveis são adequados para o problema de detecção de alimentos em imagens? Esta questão se torna relevante quando se observa que adoção adequada de métodos de seleção de variáveis implica em aumento de interpretabilidade dos resultados e aumento de desempenho dos algoritmos de predição (CALVINI *et al.*, 2015; XIAOBO *et al.*, 2010). A identificação dos métodos utilizados em combinação com os diferentes tipos de aplicações permite também o reconhecimento de oportunidades de pesquisas relacionadas.

Este artigo está organizado da seguinte maneira: a Seção 2.2 apresenta o método utilizado no desenvolvimento da revisão, detalhando critérios de busca, inclusão e exclusão de artigos e método de análise dos mesmos. A Seção 2.3 descreve o conjunto de artigos encontrados na seção anterior, organizando e apresentando os métodos utilizados pelos autores. A Seção 2.4 discute a utilização dos métodos em diferentes tipos de aplicações, e aponta as oportunidades de pesquisa relacionadas ao tema. A Seção 2.5 é dedicada às conclusões, resumindo os principais resultados encontrados.

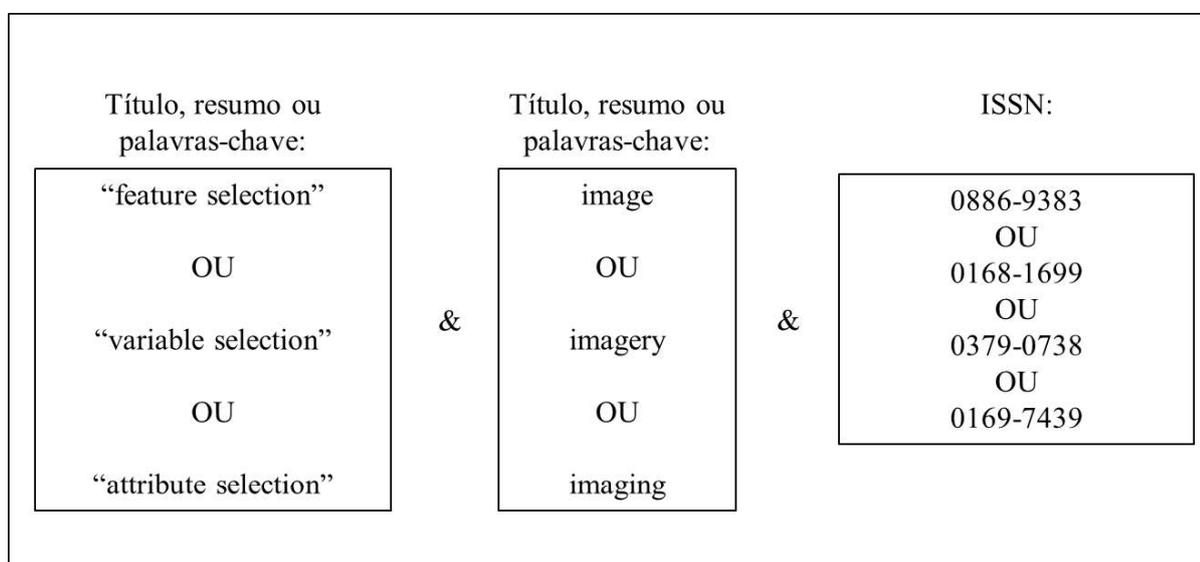
## 2.2 Método

Neste contexto, e de forma a responder a questão de pesquisa acima apresentada, o presente artigo propõe-se a fazer uma revisão sistemática de literatura abordando os métodos de seleção de variáveis no contexto de predição em aplicações envolvendo identificação/detecção de

alimentos com base em imagens. Para garantir a reprodutibilidade e o rigor da análise, uma série de passos foi adotada para a definição do conjunto de artigos utilizados na revisão.

Inicialmente, foi conduzida uma exploração livre com o intuito de definir as palavras-chave a serem utilizadas na pesquisa. Uma busca na base de dados *Scopus* foi executada usando o termo “*feature selection*”, e os artigos resultantes diretamente relacionados com o tópico de pesquisa foram examinados em busca de termos alternativos para palavra-chave. O mesmo procedimento foi repetido para o termo “*image*”. O resultado desta etapa exploratória é a definição de dois grupos de termos a serem utilizados como palavra-chave: (“*feature selection*” OU “*variable selection*” OU “*attribute selection*”) E (“*image*” OU “*imagery*” OU “*imaging*”).

Para atingir os artigos referentes a aplicações envolvendo detecção de alimentos, foi definido um conjunto de quatro periódicos referências no tópico de pesquisa. Os periódicos selecionados são: “*Chemometrics and Intelligent Laboratory Systems*”, “*Computers and Electronics in Agriculture*”, “*Forensic Science International*” e “*Journal of Chemometrics*”. A escolha por este conjunto de periódicos deve-se ao fato de os mesmos serem referência em aplicações agrícolas ou alimentícias. A restrição referente aos periódicos é feita através do campo ISSN na busca. A Figura 2.1 ilustra a combinação de termos utilizada na busca.



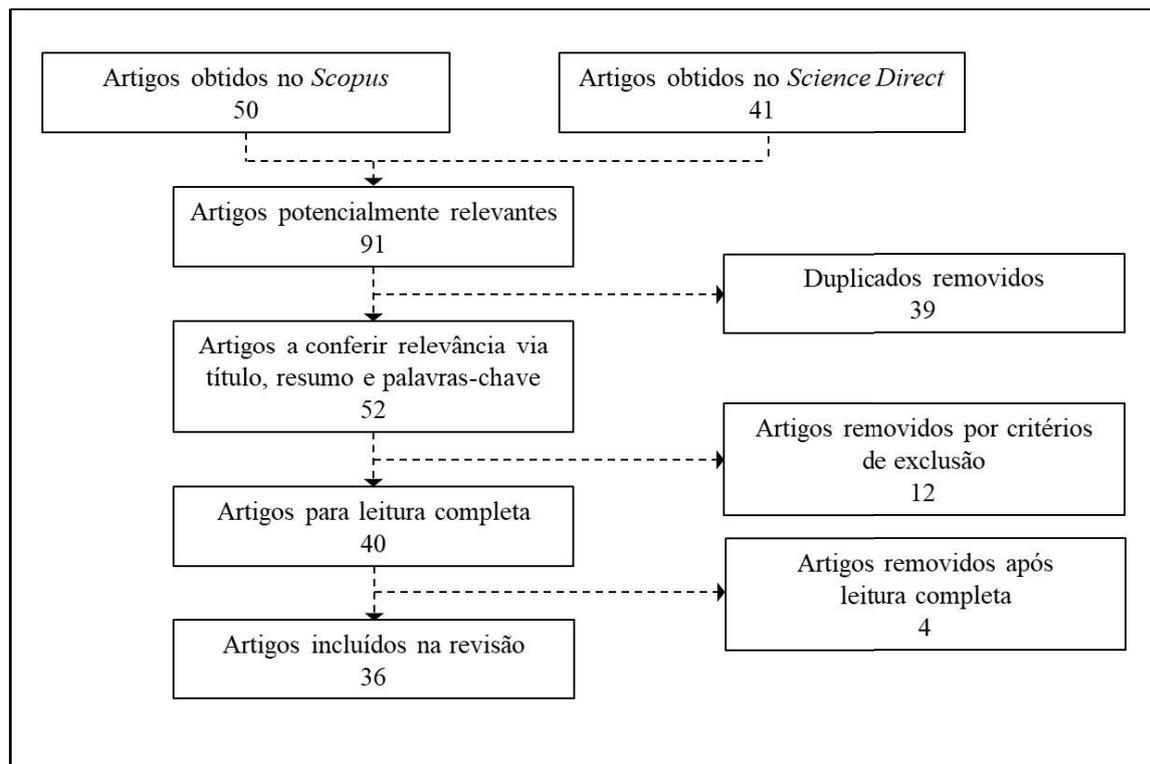
**Figura 2.1** - Combinação de termos para busca

Uma vez que a motivação deste trabalho é identificar oportunidades de aplicação de métodos de seleção de variáveis, e que a adequação da aplicação destes métodos está mais

relacionada ao formato dos dados de entrada do que o contexto de aplicação propriamente, os artigos resultantes que abordam utilização de métodos de seleção de variáveis em aplicações diferentes da agrícola/alimentícia foram também mantidos na análise. Desta forma, foram considerados também artigos envolvendo análise forense, predição de propriedades químicas e detecção de animais, entre outros. A análise de tais artigos permite identificar potenciais novos métodos a serem utilizados em aplicações alimentícias.

A busca ocorreu em dezembro de 2019, e utilizou dois dos sites de busca acadêmica mais relevantes: *ScienceDirect* e *Scopus*. *ScienceDirect* oferece mais de 9,5 milhões de artigos e capítulos de livro (TOBER, 2011), enquanto *Scopus* afirma ser a maior base de resumos e citações de literatura científica na internet (BAR-ILAN, 2007). Foram mantidos apenas artigos em inglês, e publicados em um período de dez anos (2010 a 2019), para garantir a atualidade e alinhamento da revisão com as tendências do campo de pesquisa. Os critérios de exclusão adotados são (i) repetição de artigo, (ii) não utilização de imagem como objeto básico da análise (por exemplo, artigos que utilizam bases de dados tabulares), e (iii) ausência de aplicação de algum método de seleção de variáveis no processo de análise.

A Figura 2.2 resume o processo de seleção dos artigos. Para a execução do processo, foi utilizado o software *StArt*, desenvolvido para auxiliar na execução de revisões sistemáticas, e que oferece funcionalidades como visualização dos artigos obtidos, avaliação da qualidade das buscas e sumarização dos dados (FABBRI *et al.*, 2012). O conjunto inicial foi composto por 91 artigos, sendo 50 resultantes da busca no *Scopus* e 41 resultantes da busca no *ScienceDirect*. Uma busca por artigos duplicados resultou na exclusão de 39 artigos, gerando um subconjunto com 52 artigos únicos, cujo título, resumo e palavras-chave foram lidos e submetidos aos critérios de exclusão definidos. Após a aplicação dos critérios de exclusão, 12 artigos foram removidos da análise, resultando no conjunto de 40 artigos selecionados para leitura completa, e com alto potencial de serem mantidos na análise. A leitura deste conjunto de artigos identificou quatro trabalhos que não atingiram os critérios de exclusão, de forma que o conjunto final constituinte da análise foi composto de 36 artigos.



**Figura 2.2** - Diagrama resumindo o fluxo de seleção de artigos

### 2.3 Descrição

Os métodos de seleção de variáveis são usualmente classificados entre *filter*, *wrapper* e *embedded*. Os métodos do tipo *filter*, ou de filtragem, promovem a seleção de subconjuntos de variáveis como uma etapa de pré-processamento, de forma independente do algoritmo de predição. Medidas estatísticas são utilizadas para ordenar as variáveis, e os preditores posicionados abaixo de um determinado ponto de corte são excluídos. Por outro lado, os métodos do tipo *wrapper* baseiam-se na aplicação de algum algoritmo de aprendizagem para quantificar a qualidade dos subconjuntos de variáveis candidatos. Por este motivo, estes geralmente são apresentados melhor desempenho em relação à tarefa de predição. Em contrapartida, podem ser difíceis de implementar em dados com alta dimensionalidade e apresentar baixo desempenho computacional (ABOUDI; BENHLIMA, 2016; CHEN *et al.*, 2018; ESTÉVEZ *et al.*, 2009). Por fim, nos métodos do tipo *embedded*, o algoritmo de seleção de variáveis é integrado como parte do algoritmo de aprendizado, sendo incorporado ao processo de treinamento. Estes métodos combinam qualidades dos dois métodos anteriormente citados (CHANDRASHEKAR; SAHIN,

2014). Dado que se observou uma quantidade reduzida de artigos abordando métodos do tipo *embedded*, e que estes métodos apresentam similaridades em relação aos métodos do tipo *wrapper*, as ocorrências de métodos *embedded* foram incorporadas à seção referente aos métodos *wrapper*. As duas subseções seguintes dedicam-se à descrição dos principais métodos de seleção de variáveis dos tipos *filter* e *wrapper* (e *embedded*) encontrados na literatura, e na forma como foram empregados nos respectivos contextos de predição.

### 2.3.1 Métodos tipo *Filter*

Os métodos do tipo *filter* configuram-se como as primeiras abordagens adotadas para seleção de variáveis. Por excluírem as variáveis irrelevantes antes de treinar os algoritmos de predição, estes métodos geralmente são mais rápidos computacionalmente, principalmente quando aplicados a dados de alta dimensionalidade. Entre os métodos mais populares, podem ser citados *Gini index*, *mutual information* e *covariance* (ABOUDI; BENHLIMA, 2016; CHEN *et al.*, 2018).

O método *Gini index* se utiliza dos métodos baseados em árvore, como *Classification And Regression Trees* (CART) ou *Random Forest* (RF), para atribuir uma medida de importância para cada variável. A importância referente a cada variável está relacionada com a frequência e significância com que a variável é utilizada como critério de segmentação na árvore (YU *et al.*, 2006). A utilização do método com o propósito de conduzir seleção de variáveis foi explorada em diferentes aplicações. Sandhu *et al.* (2019) utilizaram diversos classificadores para reconhecer a presença de doenças em folhas de manjeriço a partir de imagens. Antes de aplicar os métodos de classificação, os autores usaram o *Gini index* derivado de *Random Forest* para ordenar as variáveis conforme a importância. Os autores propuseram um novo algoritmo de classificação, baseado no conceito de sobrevivência do mais forte, e o compararam a outros onze algoritmos existentes - *Random Forest*, *Naive Bayes*, *K-Nearest Neighbors* (KNN), *Support Vector Machine* (SVM), *Discriminant Analysis* (DA), *Bayesian Generalized Linear Model*, *Gaussian Process*, *Extreme Gradient Boosting*, *Bagging*, *Conditional Inference Tree*, *Flexible Discriminant Analysis*. De maneira análoga, Gilbertson e Van Niekerk (2017) aplicaram o *Gini index* baseado em RF e CART para ordenar as variáveis em um problema de classificação de culturas agrícolas a partir de imagens de satélite. Após ordenação, diversos subconjuntos de variáveis foram

definidos e utilizados para treinar quatro algoritmos de classificação - *Decision Trees* (DT), KNN, RF e SVM.

Outra métrica comumente utilizada para selecionar variáveis é conhecida como *Mutual Information* (MI), método que analisa quantitativamente a relação entre duas variáveis (LA *et al.*, 2012). Este método utiliza os conceitos de função de densidade de probabilidade das variáveis cuja relação se quer investigar, e indica a quantidade de incerteza em uma variável que é removida ao conhecer-se a outra. Existem diferentes abordagens que se aproveitam do conceito de MI para seleção de variáveis. Uma forma simples consiste em calcular o MI para todos os possíveis pares de variáveis no conjunto de dados, eliminando os pares que apresentarem valor superior a um determinado valor mínimo, e mantendo os demais (LIU *et al.*, 2017). Esta estratégia foi adotada por Liu *et al.* (2017) como forma de selecionar as melhores variáveis numa aplicação de classificação de brotos de videira com base em imagens. Após selecionar as variáveis, os autores aplicaram uma combinação de *Principal Component Analysis* (PCA) com *k-means* como classificador. Borges *et al.* (2017) adaptaram esse conceito ao utilizar o *Joint Mutual Information Score*, o qual avalia não simplesmente a relação entre duas variáveis, mas a informação entre variáveis aleatórias conjuntas e uma variável alvo. Os autores utilizaram o método em combinação com *Logistic Regression* (LR) numa aplicação forense para detecção de faces.

O método mRMR (*Minimum Redundancy Maximum Relevance*) também utiliza o conceito de MI, porém de forma um pouco mais elaborada. Este método combina medidas de relevância e redundância numa mesma métrica de forma a valorizar a primeira e penalizar a segunda. Neste caso, a relevância é avaliada pela MI entre cada variável preditora e a variável dependente, enquanto a redundância é medida pela MI entre todos os pares de variáveis predictoras (JIANG; LI, 2015; PARK *et al.*, 2018; ZHANG *et al.*, 2017). Park *et al.* (2018) utilizaram este método para selecionar as melhores bandas hiperespectrais para identificação e classificação de doenças em folhas de maçãs, executando uma busca incremental pelo subconjunto ótimo de variáveis. As bandas selecionadas foram inseridas num modelo de *deep learning* composto por *Convolutional Neural Networks* associado a *Fully Connected Network*. Este método também foi utilizado na tarefa de detecção de corpos estranhos em algodão, na qual

os autores fizeram aplicação dos classificadores *Linear Discriminant Analysis* (LDA), SVM e *Artificial Neural Network* (ANN) (JIANG; LI, 2015; ZHANG *et al.*, 2017).

Similar ao MI, a métrica *Pearson correlation* mede a associação linear entre duas variáveis contínuas. *Correlation-based feature selection* (CFS) usualmente associa uma estratégia de busca heurística com a métrica *Pearson correlation* (SÁNCHEZ-MAROÑO *et al.*, 2007). Silva *et al.* (2015) adaptaram este conceito na tarefa de identificação de subespécies de abelha, propondo uma estratégia na qual a matriz de correlação entre as variáveis é calculada, e as variáveis correspondentes aos elementos com os maiores valores são excluídas até atingir-se um número determinado de variáveis. O classificador *Naive Bayes* foi então utilizado. Mollazade *et al.* (2012) e Silva *et al.* (2013) utilizaram o CFS com o conhecido algoritmo de busca *best first*. Os primeiros aplicaram os classificadores ANN, SVM, DT e Bayesian Network para classificar diferentes níveis de qualidade de passas, enquanto os últimos utilizou ANN, SVM, DT, naive Bayes (NB), KNN, LR, RF e *Partial Least Squares* (PLS) para classificar mudas de plantas de acordo com diferentes estágios de desenvolvimento.

Algumas técnicas para seleção de variáveis fazem uso de projeções do conjunto de dados, e não propriamente dos dados originais. PCA e PLS são algumas dessas técnicas mais conhecidas. Enquanto a primeira promove uma transformação nos dados de forma a encontrar as direções que maximizam a variância no conjunto de variáveis preditoras, a segunda gera combinações lineares entre variáveis preditoras e resposta, maximizando a covariância entre os dois grupos (MALHI; GAO, 2005). Sharif *et al.* (2018) utilizaram PCA para seleção de variáveis num problema de classificação de tipos de doenças em plantas cítricas. Obtidos os componentes principais, os autores utilizaram covariância e entropia para selecionar os melhores componentes, e então treinaram um modelo SVM.

Métodos como PCA e PLS apresentam uma fraqueza evidente: a dificuldade de interpretar os componentes principais derivados, uma vez que os mesmos são combinações lineares de todas as variáveis preditoras. Para superar essa restrição, modelos esparsos, como *Sparse Principal Component Analysis* (sPCA) e *Sparse Partial Least Squares* (sPLS), induzem esparsidade nas cargas ou coeficientes, reduzindo o número de variáveis representadas pelos componentes. Calvini *et al.* (2015) compararam as técnicas clássicas com as esparsas, ao classificar dois tipos de espécies de café utilizando imagens hiperespectrais. Os autores utilizaram

PCA acoplado com KNN e PLS acoplado com DA, e compararam o desempenho obtido ao utilizar os métodos esparsos equivalentes, sPCA e sPLS.

Outro método baseado no conceito de projeção dos dados é o *Orthogonal Subspace Projection* (OSP), o qual identifica o melhor subconjunto de variáveis ao executar uma busca sequencial na qual projeta as variáveis preditoras nos subespaços ortogonais de cada variável preditora. Este método foi utilizado por Shuaibu *et al.* (2018) para detecção de diferentes estágios de doença em maçãs, através de imagens hiperespectrais, em combinação com os classificadores *ensemble bagged*, DT e *weighted KNN*.

Ainda entre os métodos de filtragem de variáveis, a análise de sensibilidade é uma das opções menos complexas, sendo empregada para avaliar a influência de cada preditor na variável alvo (SADEGHYAN, 2018). Em Teimouri *et al.* (2014), a análise de sensibilidade em relação à intensidade de atributos de cores foi utilizada para ordenar e filtrar variáveis e posteriormente classificar imagens de amêndoas entre objeto, sombra e fundo. Neste estudo, a diferença de valor entre as classes, para determinado atributo, foi associada à qualidade do atributo. As variáveis selecionadas foram inseridas num modelo de ANN.

Outras técnicas simples muito utilizadas para o ordenamento de variáveis são os testes estatísticos t de independência e *chi-squared*. O primeiro foi utilizado por Chen *et al.* (2018), em combinação com os classificadores SVM e RF, para detectar presença de fungos em plantações de trigo através de imagens de satélite. O segundo foi explorado nos já citados estudos de Silva *et al.* (2013) e Silva *et al.* (2015), os quais ainda exploraram a métrica *Information Gain* como forma de ordenar as variáveis.

Phadikar *et al.* (2013) propuseram a aplicação de *rough set theory* para seleção de variáveis na classificação de diferentes doenças em folhas de arroz. *Rough set theory* é um conjunto de ferramentas originado na ciência da computação, capaz de identificar dependências parciais ou totais nos dados e eliminar variáveis redundantes (JENSEN; SHEN, 2007). Mehdizadeh (2019) usou *linguistic hedge* para selecionar as variáveis extraídas e aplicar *fuzzy logic* para determinar a quantidade requerida de água em plantas do tipo lírio. O algoritmo *linguistic hedge* para seleção de variáveis baseia-se em regras *fuzzy*. As variáveis são submetidas ao conjunto de regras *fuzzy*, de forma que as variáveis relevantes são enfatizadas por potências não nulas e as irrelevantes são suprimidas por potências nulas (AZAR, 2014).

### 2.3.2 Métodos tipo *Wrapper*

Métodos de seleção de variáveis do tipo *wrapper*, de forma geral, são compostos por uma estratégia de busca do subconjunto ótimo de variáveis e uma função objetivo para avaliação da qualidade de cada subconjunto. Em relação à estratégia de busca, tais métodos podem ser segregados em dois principais grupos: abordagens baseadas em população e estratégias de busca sequencial (ABOUDI; BENHLIMA, 2016). O método mais difundido pertencente ao primeiro grupo é o *Genetic Algorithm* (GA), enquanto o segundo grupo é dominado pelos métodos *Sequential Forward Feature Selection* (SFFS) e *Sequential Backward Feature Selection* (SBFS).

SFFS e SBFS são utilizados com o propósito de determinar o melhor subconjunto de variáveis em relação ao desempenho de predição. Nestes, um algoritmo de busca sequencial adiciona variáveis (SFFS) ou remove variáveis (SBFS) de um subconjunto candidato, guiado por uma função de avaliação do desempenho do subconjunto (ARTHUR *et al.*, 2018; LI *et al.*, 2014). A principal vantagem dos métodos baseados na adição de variáveis refere-se ao desempenho computacional, uma vez que é mais rápido treinar modelos quando há um número reduzido de variáveis. Por outro lado, partir do conjunto completo de variáveis pode identificar mais facilmente a interação entre variáveis (KOHAVI; JOHN, 1997). As duas abordagens foram utilizadas por Arthur *et al.* (2018) na tentativa de distinção de dois tipos de manchas de sangue por respingo. Para avaliar o desempenho de cada subconjunto, os autores adotaram como função de avaliação os métodos *1-Nearest Neighbor*, *inter-intra distance* e *sum of the estimated Mahalanobis distance*, enquanto os classificadores LDA e *Quadratic Discriminant Analysis* (QDA) foram aplicados para predição das classes. Li *et al.* (2014) fizeram uso apenas de SFFS no estudo que teve como objetivo a identificação de diferentes estágios de crescimento de mirtilo. Os autores usaram os algoritmos KNN, NB e *supervised k-means*, tanto na etapa de seleção de variáveis quanto na etapa de classificação.

Alguns autores fazem uso de algoritmos híbridos que combinam as abordagens *Forward Feature Selection* (FFS) ou *Backward Feature Selection* (BFS) a novas funcionalidades, gerando métodos como *Sequential Floating Forward Feature Selection* (SFFFS) ou *Sequential Floating Backward Feature Selection* (SFBFS). Estes métodos intercalam as etapas de adição e remoção de variáveis, partindo de um conjunto vazio (SFFFS) ou completo (SFBFS) de variáveis. As etapas de adição ou remoção de variáveis só ocorrem se estas resultarem em aumento de

desempenho do subconjunto, o que caracteriza os métodos como autocontrolados (PUDIL *et al.*, 1994; UNAY *et al.*, 2011). A abordagem SFFFS foi utilizada por Bac *et al.* (2013) e Unay *et al.* (2011) nas tarefas, respectivamente, de identificação de partes de plantas de pimentão e identificação do nível de qualidade de maçãs, ambas com base em imagens. Os primeiros utilizaram o algoritmo CART, tanto para avaliar os subconjuntos de variáveis quanto para prever as classes, enquanto os últimos adotaram os algoritmos LDA, KNN, *Fuzzy* KNN, SVM e *Decision Tree C4.5* para as tarefas de seleção de variáveis e classificação. Já Mahmud *et al.* (2019) e Torimitsu *et al.* (2016) adotaram *stepwise discriminant analysis*, uma variação do SFFFS, que também utiliza o mecanismo de inclusão e exclusão de variáveis. Neste método, a adição ou remoção de variáveis é governada pelo valor de significância da variável (“*F to enter*” e “*F to remove*”), em comparação com algum valor referência pré-estabelecido. A avaliação dos subconjuntos é resultante da aplicação de funções discriminantes. Mahmud *et al.* (2019) propuseram este método para identificar doenças em folhas de morango a partir de imagens, combinado com o classificador QDA, enquanto Torimitsu *et al.* (2016) buscaram a identificação do sexo de corpos através de imagens de tomografia da coluna, e usou DFA como algoritmo de predição.

Enquanto alguns métodos operam com busca sequencial do melhor subconjunto de variáveis, os métodos baseados em população adotam heurísticas que tentam espelhar os princípios de evolução observados na natureza. Entre estes, o GA destaca-se por apresentar boa relação entre qualidade da solução fornecida e desempenho computacional. O método apresenta uma população de soluções definida inicialmente de forma aleatória, a qual é iterativamente submetida a mutações e recombinações também aleatórias. Uma função de avaliação de desempenho determina quais soluções passam para a próxima geração, de forma a favorecer a manutenção apenas das melhores soluções (ABOUDI; BENHLIMA, 2016; BEHROOZI-KHAZAEI; MALEKI, 2017). A utilização do algoritmo genético para seleção de variáveis foi proposta por Behroozi-Khazaei e Maleki (2017) no estudo que implementou ANN para segmentação de imagens de uva entre fruto, folhas e fundo. Neste caso, o GA foi utilizado não apenas para determinar o conjunto ótimo de variáveis, mas também para otimizar a configuração da rede neural. Khan *et al.* (2018) também aplicaram GA na etapa de seleção de variáveis, antes de utilizar SVM para detectar e classificar doenças em maçãs e bananas.

Outro método baseado no conceito de população é o *Artificial Bee Colony* (ABC), algoritmo de otimização estocástica espelhado no comportamento de colônia de abelhas durante o processo de busca por alimento. No contexto de seleção de variáveis, o problema de encontrar o subconjunto ótimo de variáveis é convertido na tarefa de encontrar o melhor vetor de parâmetros de forma a minimizar o erro de predição. Uma população é aleatoriamente definida como solução inicial, e iterativamente melhorada pelo mecanismo de busca por vizinhos, abandonando soluções inferiores (KARABOGA; BASTURK, 2007; TAHERI-GARAVAND *et al.*, 2019). Taheri-Garavand *et al.* (2019) propuseram um modelo híbrido composto pelo algoritmo ABC e pelo classificador ANN, no qual o ANN foi utilizado para avaliar a qualidade das soluções intermediárias. Após definição do subconjunto ótimo de variáveis, foram empregados os classificadores SVM, KNN e ANN na tentativa de diagnosticar o frescor de peixes do tipo carpa.

Alguns autores adotam estratégias que confrontam métodos de busca sequenciais com métodos baseados em população, como fizeram Niazi *et al.* (2014) ao comparar GA com PLS na predição do potencial de redução de compostos químicos através da imagem da estrutura dos compostos. Para selecionar o conjunto ótimo de atributos via PLS, os autores testaram diferentes números de variáveis latentes e avaliaram o erro de predição resultante. Nas duas abordagens, os autores aplicaram PCA nos dados originais antes de implementar a seleção de variáveis.

Silla *et al.* (2011) propuseram uma estratégia similar, ao comparar *Interval Partial Least Squares* (iPLS) com GA acoplado a PLS para seleção de pixels de imagem na predição de propriedades cinéticas de compostos de medicamentos. O método iPLS promove seleção de variáveis ao dividir o espaço dos atributos (por exemplo conjunto de pixels) em intervalos de mesma largura e treinar um modelo PLS em cada um dos intervalos. O intervalo que resultou no menor erro de predição é selecionado como primeiro intervalo, e modelos com base em dois intervalos são treinados ao adicionar-se cada um dos outros intervalos ao primeiro selecionado. O melhor par de intervalos é escolhido, e o procedimento segue adicionando intervalos até que não haja melhoria significativa de desempenho (ULRICI *et al.*, 2013).

Outra forma de utilizar iPLS em conjunto com outros métodos é através da combinação dos métodos. O método iPLS foi concatenado ao classificador *Discriminant Analysis* por Ulrici *et al.* (2013), resultando no modelo preditivo iPLS-DA, composto por dois principais procedimentos: construção de componentes PLS e construção de modelo de predição (LEE;

LIONG, 2018). Neste caso, o objetivo dos autores foi discriminar dois tipos de polímeros com base em imagens. De forma análoga, Jia *et al.* (2019) utilizaram iPLS em conjunto com *Successive Projection Algorithm* (SPA) para selecionar os comprimentos de onda ótimos a serem usados numa regressão PLS para estimar a biomassa de folhas de trigo a partir de imagens hiperespectrais. O método SPA é uma técnica de seleção de variáveis que busca minimizar os efeitos de colinearidade nos dados de treinamento. Consiste numa sequência de operações de projeção das variáveis preditoras, partindo de uma variável aleatoriamente selecionada e sucessivamente adicionando as variáveis que apresentam a menor colinearidade em relação às anteriormente adicionadas. O subconjunto ótimo é determinado em função do erro de validação. Esta técnica foi adotada por Zhang *et al.* (2019) para selecionar as faixas de comprimento de onda mais relevantes oriundos de imagens hiperespectrais e identificar e separar arroz de dois tipos de ervas danosas. Para a tarefa de classificação, os autores usaram RF e SVM.

A exploração de métodos sequenciais e métodos baseados em população também pode ser observada em Sun *et al.* (2019). Os autores aplicaram o método SPA em conjunto com *stepwise regression* para prever o nível de umidade presente em folhas de chá a partir de imagens hiperespectrais. Esta abordagem foi comparada com a alternativa, baseada na combinação dos algoritmos *Competitive Adaptive Reweighted Sampling* (CARS) com *Stepwise Regression*, e em ambas *Multiple Linear Regression* foi utilizada para a predição final. O algoritmo CARS parte de uma população de variáveis aleatoriamente selecionadas e conduz uma amostragem ponderada, repetindo o processo N vezes. O melhor dos N subconjunto de variáveis é determinado com base no erro de predição resultante do treinamento de regressão PLS (LI *et al.*, 2009).

Algumas técnicas encontradas com menor frequência são *Conditional Mutual Information Maximization* (CMIM), *permutation testing* e *L1-Regularized Logistic Regression*. A primeira baseia-se na métrica *mutual information*, selecionando variáveis relevantes e evitando redundância. As variáveis são selecionadas de forma iterativa de forma a maximizar a medida *mutual information* entre o conjunto de preditores já selecionados e a variável alvo, e as variáveis que apresentam similaridade com as já adicionadas são excluídas. Galdames *et al.* (2019) propuseram a utilização de CMIM para reduzir o número de variáveis hiperespectrais na classificação de tipos de rocha, aplicando os classificadores SVM e RF no dados extraídos de imagens.

*L1-Regularized Logistic Regression* foi explorado por Dumont *et al.* (2015) para avaliar a qualidade de sementes de abeto da Noruega. Nesta abordagem, cada coeficiente da regressão logística foi associado a um preditor, e a regularização dos parâmetros foi conduzida via otimização bayesiana. Desta forma, as variáveis associadas a coeficientes nulos foram excluídas, enquanto as associadas aos coeficientes relevantes compuseram o conjunto final (DUMONT *et al.*, 2015).

Folch-Fortuny *et al.* (2016) usaram o método *permutation testing* para selecionar faixas espectrais utilizadas identificar doenças em frutas cítricas através de imagens. *N-way Partial Least Squares* acoplado a DA foi utilizado para a tarefa de classificação. Segundo Westerhuis *et al.* (2008), *permutation testing* promove seleção das melhores variáveis ao comparar o valor da métrica VIP (*Variable Importance in Projection*) de cada variável num modelo real com o valor VIP da mesma variável em um modelo no qual os rótulos das classes foram aleatoriamente trocados. A relevância de cada variável está associada com a probabilidade de se observar aleatoriamente um valor VIP igual ou superior ao valor real obtido.

## 2.4 Análise e Discussão

Analisando o conjunto de artigos pela perspectiva do contexto de aplicação, e ensaiando um simples agrupamento dos achados, percebe-se que a aplicação mais frequente é a alimentícia ou agrícola. 24 dos 36 artigos analisados aplicam métodos de seleção de variáveis em problemas desta natureza, o que representa dois terços do total. Dentro deste grupo, nove artigos, ou 37,5%, referem-se especificamente a detecção ou classificação de alimentos, outros nove abordam detecção de presença de doenças em alimentos, e seis (25%) propõem-se a identificar o nível de qualidade ou estágio de crescimento de alimentos. Em relação aos demais 12 artigos, quatro referem-se à detecção de plantas (umidade, corpos estranhos), três contêm aplicações forenses, dois abordam a predição de propriedades químicas, um contém identificação de espécies de animais, um envolve discriminação de polímeros e um conduz classificação de tipos de rochas. Em relação aos tipos de métodos adotados, 18 artigos, representando 50% do total, propuseram métodos do tipo *wrapper*, enquanto 14 implementaram métodos do tipo *filter* (39%), e apenas quatro exploraram as duas abordagens (11%).

Na seção atual, é apresentada uma proposta de categorização dos métodos descritos na seção anterior, tomando como dimensões principais (i) a técnica adotada, (ii) o tipo do método (*filter* ou *wrapper*) e (iii) o tipo de aplicação na qual o método foi explorado. A proposta é representada no diagrama da Figura 2.3. Nesta, os números no interior da tabela referem-se aos artigos, identificados na legenda abaixo da Figura; a linha na qual o número se encontra indica o método utilizado, enquanto a coluna informa o tipo de aplicação. A dimensão referente às técnicas abordadas, representada no eixo vertical no lado direito do diagrama, foi obtida agrupando-se algumas técnicas por critério de semelhança. As técnicas com maior frequência de utilização foram atribuídas a grupos homogêneos, como ocorre com *mutual information*, que foi proposta por cinco autores e atribuída a um grupo próprio. Técnicas foram consideradas semelhantes ao apresentar conceitos ou princípios similares, como no caso dos algoritmos baseados em projeção das variáveis preditoras e/ou independentes, reunidos sob o rótulo “Projeção (PCA ou PLS ou OSP)”. Para reduzir o número de linhas do diagrama da Figura 2.3 e facilitar a compreensão do mesmo, algumas técnicas com menor frequência de citação também foram agrupadas, mesmo que os conceitos a elas relacionados sejam diferentes. Analogamente à dimensão (i), na dimensão (iii), os tipos de aplicações foram agrupados conforme o objeto de interesse dos estudos. Quando o objeto de interesse era uma planta, o mesmo foi caracterizado pela parte da planta sendo analisada, como fruta, folha ou semente. As aplicações baseadas em imagens de satélite foram agrupadas em Plantação, dado que estas imagens não permitem a visualização das partes individuais das plantas, como ocorre quando o foco é folha, por exemplo. As aplicações que não abordaram alimentos como foco foram atribuídas ao grupo Outros. Apenas uma aplicação teve peixe como objeto de interesse, mas a mesma não foi incluída no grupo Outros para não misturar aplicações diferentes em relação ao foco em alimentos.

A Figura 2.3 indica que o cluster mais populoso é o referente a métodos sequenciais tipo *wrapper* em aplicações não alimentícias. Este fato não é inesperado, dado que dois terços dos estudos foram enquadrados no grupo de outras aplicações, e que os métodos do tipo sequencial pertencem à classe dos algoritmos de seleção de variáveis mais utilizados (REN *et al.*, 2008).

Em relação às aplicações envolvendo alimentos, os objetos mais frequentemente caracterizados como foco da análise são frutas e folhas, representadas em 25 trabalhos. Apenas três artigos exploraram imagens com foco em sementes de alimentos. A mesma observação vale

para imagens de plantações, enquanto apenas um trabalho abordou análise de imagens de peixes. O baixo número de resultados referentes a estas aplicações pode indicar ser necessária alguma alteração no processo de busca de artigos, para garantir que de fato existem poucos trabalhos com tal abordagem.

	Plantação	Peixe	Fruta	Folha	Semente	Outros	
FILTER			3	2		1 4 5	Mutual Information
	7			6			Gini Index
			8 9 11	9		10	Covariance
			11 13		12		Projeção (PCA ou PLS ou OSP)
	16		9 15	9 35 36	14	10	Outros (sensitivity, chi2, t test, info gain, wilke's lambda, fuzzy, rough set)
WRAPPER	16		18 19 20	19 21		4 5 10 17 22	Sequenciais (BFS ou FFS ou Stepwise DFA)
		23	24 25	25		26 27	População (ABC ou GA)
				29 30 31		26 27 28	Projeção (PLS ou SPA)
			34	31	33	32	Outros (CARS ou CMIM ou L1 ou permutation)

1 - Borges *et al.*, 2017

4 - Jiang; Li, 2015

7 - Gilbertson; Van Niekerk, 2017

10 - Silva *et al.*, 2015

13 - Shuaibu *et al.*, 2018

16 - Chen *et al.*, 2018

19 - Bac *et al.*, 2013

22 - Torimitsu *et al.*, 2016

25 - Behroozi-Khazaei; Maleki, 2017

28 - Ulrici *et al.*, 2013

31 - Sun *et al.*, 2019

34 - Folch-Fortuny *et al.*, 2016

2 - Park *et al.*, 2018

5 - Zhang *et al.*, 2017

8 - Mollazade *et al.*, 2012

11 - Sharif *et al.*, 2018

14 - Teimouri *et al.*, 2014

17 - Arthur *et al.*, 2018

20 - Unay *et al.*, 2011

23 - Taheri-Garavand *et al.*, 2019

26 - Niazi *et al.*, 2014

29 - Jia *et al.*, 2019

32 - Galdames *et al.*, 2019

35 - Phadikar *et al.*, 2013

3 - Liu *et al.*, 2017

6 - Sandhu *et al.*, 2019

9 - Silva *et al.*, 2013

12 - Calvini *et al.*, 2015

15 - Satorres *et al.*, 2018

18 - Li *et al.*, 2014

21 - Mahmud *et al.*, 2019

24 - Khan *et al.*, 2008

27 - Silla *et al.*, 2011

30 - Zhang *et al.*, 2019

33 - Dumont *et al.*, 2015

36 - Mehdizadeh, 2019

**Figura 2.3** - Abordagens de seleção de variáveis agrupadas por tipo de aplicação e técnica

Nas aplicações com foco em frutas e folhas, observa-se uma distribuição equilibrada entre métodos do tipo *filter* e *wrapper*, assim como entre as diferentes técnicas utilizadas. As técnicas mais utilizadas são do grupo *Covariance* entre as técnicas de filtragem, e do grupo *Sequenciais* entre as abordagens *wrapper*. Apenas dois dos 25 trabalhos sobre frutas ou folhas exploraram técnicas do grupo *Mutual Information*, em contraste com a razão de três trabalhos em 16 em aplicações do tipo Outros. Por outro lado, três artigos aplicaram métodos de filtragem baseados em projeção em aplicações de alimentos, contra nenhuma ocorrência nas demais aplicações.

A esparsidade da tabela apresentada na Figura 2.3 indica que existem oportunidades de pesquisa em combinação de métodos de seleção de variáveis e aplicações. Os clusters vazios ou pouco preenchidos são sinalizadores destas oportunidades. Trabalhos futuros podem explorar a utilização em conjunto de métodos de filtragem e *wrapper*. Apenas quatro autores adotaram tal abordagem, o que representa em torno de 11% do total, sendo que apenas um destes teve alimento como foco da análise. Além disso, as quatro abordagens que combinaram *filter* com *wrapper* focaram em métodos sequencias. Considerando as características positivas de cada tipo de método, a exploração de ambos tem potencial para apresentar baixo esforço computacional aliado à alta capacidade de predição (ABOUDI; BENHLIMA, 2016).

Em relação aos tipos de aplicações, parece existir uma oportunidade de exploração de imagens com foco em sementes de alimentos. Poucos trabalhos seguiram tal abordagem, e imperfeições no processo de busca de artigos não parece ser a justificativa para esse número tão baixo, dado que foram incluídos os resultados publicados no periódico “*Computers and Electronics in Agriculture*”, o qual abrange pesquisas referentes a agricultura, agronomia e horticultura (ELSEVIER, 2020). O mesmo raciocínio é válido para as aplicações com base em imagens de plantações.

Analisando o cruzamento entre aplicações e métodos, observa-se a oportunidade de pesquisar a utilização de métodos *wrapper* do grupo Projeção em aplicações com foco em frutas, dada a ausência de trabalhos seguindo essa estratégia. Frutas foram os objetos mais explorados no universo de trabalhos revisados, aparecendo em 14 artigos, o que confirma a relevância deste tipo de aplicação. Nos métodos de filtragem, por outro lado, as aplicações onde se observa oportunidade são aquelas com foco em folhas, em cruzamento com métodos de Projeção (PCA ou PLS ou OSP). O fato de os métodos baseados em projeção, sejam do tipo *filter* ou *wrapper*,

terem sido bastante explorados em algumas aplicações e fracamente em outras se configura como oportunidade de pesquisa porque as aplicações são similares e os métodos podem ser transferidos entre diferentes aplicações.

## 2.5 Conclusão

Neste artigo foram investigados os métodos de seleção de variáveis utilizados na detecção de alimentos através de imagens. A utilização de métodos computacionais no auxílio de detecção de alimentos permite automatizar a tarefa, enquanto a adoção de métodos de seleção de variáveis leva a maior interpretabilidade e melhor desempenho na predição (XIAOBO *et al.*, 2010).

Um conjunto de 36 artigos constituiu a amostra estudada na revisão, obtidos através de uma busca nos bancos de dados online *Scopus* e *ScienceDirect* caracterizada pela combinação das palavras-chave (“*feature selection*” OU “*variable selection*” OU “*attribute selection*”) E (“*image*” OU “*imagery*” OU “*imaging*”). Foram explorados os periódicos “*Chemometrics and Intelligent Laboratory Systems*”, “*Computers and Electronics in Agriculture*”, “*Forensic Science International*” e “*Journal of Chemometrics*”, e artigos destes periódicos apresentando aplicações diferentes da alimentícia foram mantidos na análise.

Em relação ao contexto de aplicação, os artigos que tratam de alimentos representam dois terços do total, enquanto o restante se distribui em detecção de plantas não comestíveis (quatro artigos) e diversas outras aplicações. Sob a ótica do método de seleção de variáveis, metade dos trabalhos abordou exclusivamente métodos *wrapper*, enquanto 14 adotaram exclusivamente métodos *filter* e quatro utilizaram uma abordagem híbrida.

Os artigos analisados foram organizados em três dimensões: tipo de método de seleção de variáveis (*filter* ou *wrapper*); técnica adotada, na qual as métricas ou algoritmos foram agrupados conforme semelhança dos conceitos nos quais são embasados; e tipo de aplicação, que envolveu o agrupamento conforme o objeto de interesse analisado nas imagens. As aplicações mais frequentes são aquelas envolvendo frutas ou folhas de alimentos, sendo que estes trabalhos apresentam grande equilíbrio entre utilização de métodos *filter* e *wrapper*.

A análise da Figura 2.3 fornece a resposta para a questão de pesquisa apresentada. Em análises que utilizam imagens como dado de entrada, os métodos de filtragem mais utilizados são

*Mutual Information, Gini index, Covariance* e métodos baseados em projeção (PCA, PLS ou OSP), enquanto os métodos tipo *wrapper* mais comuns são os sequenciais, métodos baseados em população (como GA) e métodos baseados em projeção (PLS ou SPA). A análise da combinação de métodos com tipos de aplicações indica que existe espaço para novas pesquisas que explorem: métodos *wrapper* como PLS e SPA em problemas envolvendo detecção de frutas; métodos *filter* como PCA, PLS ou OSP em aplicações focadas em folhas de alimentos; e métodos dos tipos *filter* e *wrapper* combinados na mesma análise.

## 2.6 Referências

ABOUDI, N.; BENHLIMA, L. Review on wrapper feature selection approaches, **International Conference on Engineering & MIS (ICEMIS)**. IEEE, v. 1, n. 5, 2016.

ARTHUR, R. et al. An automated approach to the classification of impact spatter and cast-off bloodstain patterns. **Forensic science international**, v. 289, p. 310-319, 2018.

AZAR, A. Neuro-fuzzy feature selection approach based on linguistic hedges for medical diagnosis. **International Journal of Modelling, Identification and Control**, v. 22, p. 195., 2014.

BAC, C. W.; HEMMING, J.; VAN HENTEN, E. J. Robust pixel-based classification of obstacles for robotic harvesting of sweet-pepper. **Computers and electronics in agriculture**, v. 96, p. 148-162, 2013.

BAR-ILAN, J. Which h-index?—A comparison of WoS, Scopus and Google Scholar. **Scientometrics**, v. 74, p. 257-271, 2008.

BEHROOZI-KHAZAEI, N.; MALEKI, M. A robust algorithm based on color features for grape cluster segmentation. **Computers and Electronics in Agriculture**, v. 142, p. 41-49, 2017.

BORGES, D. et al. Photoanthropometric face iridial proportions for age estimation: An investigation using features selected via a Joint Mutual Information criterion. **Forensic Science International**, v. 284, 2017.

CALVINI, R.; ULRICI, A.; AMIGO, J. Practical comparison of sparse methods for classification of Arabica and Robusta coffee species using near infrared hyperspectral imaging. **Chemometrics and Intelligent Laboratory Systems**, 146, 2015.

CHANDRASHEKAR, G.; SAHIN, F. A survey on feature selection methods. **Computers & Electrical Engineering**, v. 40, n. 1, p. 16-28, 2014.

CHEN, D. et al. Mapping wheat rust based on high spatial resolution satellite imagery. **Computers and Electronics in Agriculture**, v. 152, p. 109-116, 2018.

DUMONT, J. et al. Thermal and hyperspectral imaging for Norway spruce (*Picea abies*) seeds screening. **Computers and Electronics in Agriculture**, v. 116, 2015.

ELSEVIER, 2020. ScienceDirect content. Elsevier. Disponível em: <<https://www.elsevier.com/solutions/sciencedirect/content>>. Acesso em: 11 de jan. de 2020.

ESTEVEZ, P. et al. Normalized Mutual Information Feature Selection. **IEEE transactions on neural networks**, v. 20, p. 189-201, 2009.

Fabbri, S. et al. Managing Literature reviews information through visualization. **Proceedings of the 14th International Conference on Enterprise Information Systems**, v. 2, p. 36-45, 2012.

FLOOD, J. The importance of plant health to food security. **Food Sec**, v. 2, p. 215–231, 2010.

FOLCH-FORTUNY, A. et al. VIS/NIR hyperspectral imaging and N-way PLS-DA models for detection of decay lesions in citrus fruits. **Chemometrics and Intelligent Laboratory Systems**, v. 156, p. 241-248, 2016.

GALDAMES, F. et al. Rock Lithological Classification by Laser Range 3D and Color Images. **International Journal of Mineral Processing**, v. 160, 2017.

GAUCHI, J. P.; CHAGNON, P. Comparison of selection methods of explanatory variables in PLS regression with application to manufacturing process data. **Chemometrics and Intelligent Laboratory Systems**, v. 58, n. 2, p. 171-193, 2001.

GILBERTSON, J.; VAN NIEKERK, A. Value of dimensionality reduction for crop differentiation with multi-temporal imagery and machine learning. **Computers and Electronics in Agriculture**, v. 142, p. 50-58, 2017.

JENSEN, R.; SHEN, Q. Rough set-based feature selection: A review. **Rough Computing: Theories, Technologies and Applications**, v. 70, p. 107, 2007.

JIA, M. et al. A newly developed method to extract the optimal hyperspectral feature for monitoring leaf biomass in wheat. **Computers and Electronics in Agriculture**, v. 165, p. 104942, 2019.

JIANG, Y.; LI, C. MRMR-based feature selection for classification of cotton foreign matter using hyperspectral imaging. **Computers and Electronics in Agriculture**, v. 119, p. 191-200, 2015.

JOVIĆ, A.; BRKIĆ, K.; BOGUNOVIĆ, N. A review of feature selection methods with applications. **2015 38th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)**. IEEE, 2015.

KARABOGA, D.; BASTURK, B. A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm. **Journal of Global Optimization**, v. 39, p. 459-471, 2007.

KARABULUT, E. M.; ÖZEL, S. A.; IBRIKCI, T. A comparative study on the effect of feature selection on classification accuracy. **Procedia Technology**, v. 1, p. 323-327, 2012.

KHAN, M. et al. CCDF: Automatic system for segmentation and recognition of fruit crops diseases based on correlation coefficient and deep CNN features. **Computers and Electronics in Agriculture**, v. 155, p. 220-236, 2018.

KOHAVI, R.; JOHN, G. Wrappers for feature selection. **Artificial Intelligence - AI**, v. 1, 1997.

LA, V. et al. A novel feature selection method based on normalized mutual information. **Applied Intelligence – APIN**, v. 37, 2012.

LEE, L.; LIONG, C.Y. Partial Least Squares-Discriminant Analysis (PLS-DA) for classification of high-dimensional (HD) data: a review of contemporary practice strategies and knowledge gaps. **The Analyst**, v. 143, 2018.

LI, H. D. et al. Key wavelength screening using competitive adaptive reweighted sampling method for multivariate calibration. **Analytica Chimica Acta**, v. 648, p. 77-84, 2009.

LI, H.; LEE, W. S.; WANG, K. Identifying blueberry fruit of different growth stages using natural outdoor color images. **Computers and Electronics in Agriculture**, v. 106, p. 91–101, 2014.

LIU, S. et al. A computer vision system for early stage grape yield estimation based on shoot detection. **Computers and Electronics in Agriculture**, v. 137, p. 88-101, 2017.

MAHMUD, M.S. et al. Development of an artificial cloud lighting condition system using machine vision for strawberry powdery mildew disease detection. **Computers and Electronics in Agriculture**, v. 158, p. 219-225, 2019.

MALHI, A.; GAO, R. PCA-Based Feature Selection Scheme for Machine Defect Classification. **IEEE Transactions on Instrumentation and Measurement**, v. 53, p. 1517 – 1525, 2005.

MEHDIZADEH, S. Design and implementation of a smart system for water management of liliun flower using image processing. **Computers and Electronics in Agriculture**, v. 160, p. 131-143, 2019.

MOLINA, L. C.; BELANCHE, L.; NEBOT, A. Feature selection algorithms: A survey and experimental evaluation. **2002 IEEE International Conference on Data Mining. Proceedings. IEEE**, 2002.

MOLLAZADE, K.; OMID, M.; AREFI, A. Comparing data mining classifiers for grading raisins based on visual features. **Computers and electronics in agriculture**, v. 84, p. 124-131, 2012.

- NIAZI, A. et al. Application of genetic algorithms for pixel selection in multivariate image analysis for a QSAR study of trypanocidal activity for quinone compounds and design new Quinone compounds. **Chemometrics and Intelligent Laboratory Systems**, v. 139, 2014.
- PARK, K. et al. Classification of apple leaf conditions in hyper-spectral images for diagnosis of Marssonina blotch using mRMR and deep neural network. **Computers and Electronics in Agriculture**, v. 148, p. 179-187, 2018.
- PHADIKAR, S.; SIL, J.; DAS, A. Rice diseases classification using feature selection and rule generation techniques. **Computers and Electronics in Agriculture**, v. 90, p. 76–85, 2013.
- PUDIL, P.; NOVOVICOVÁ, J.; KITTLER, J. Floating search methods in feature selection. **Pattern Recognition Letters**, v. 15, p. 1119-1125, 1994.
- REN, J. et al. Forward Semi-supervised Feature Selection. **Pacific-Asia conference on knowledge discovery and data mining**. Springer, Berlin, Heidelberg, p. 970-976, 2008.
- SADEGHYAN, S. A new robust feature selection method using variance-based sensitivity analysis. **arXiv preprint arXiv:1804.05092**, 2018.
- SÁNCHEZ-MAROÑO, N.; ALONSO-BETANZOS, A.; TOMBILLA-SANROMÁN, M. Filter Methods for Feature Selection – A Comparative Study. **International Conference on Intelligent Data Engineering and Automated Learning**. Springer, Berlin, Heidelberg, p. 178-187, 2007.
- SANDHU, G.; JOSHI, H.; KUMAR, V. Basil leaves disease classification and identification by incorporating survival of fittest approach. **Chemometrics and Intelligent Laboratory Systems**, v. 186, p. 1-11, 2019.
- SATORRES, S. et al. A computer vision approach based on endocarp features for the identification of olive cultivars. **Computers and Electronics in Agriculture**, v. 154, p. 341-346, 2018.
- SHAO, C. et al. Feature selection for manufacturing process monitoring using cross-validation. **Journal of Manufacturing Systems**, v. 32, n. 4, p. 550-555, 2013.
- SHARIF, M. et al. Detection and classification of citrus diseases in agriculture based on optimized weighted segmentation and feature selection. **Computers and Electronics in Agriculture**, v. 150, 2018.
- SHUAIBU, M. et al. Unsupervised hyperspectral band selection for apple Marssonina blotch detection. **Computers and Electronics in Agriculture**, v. 148, p. 45-53, 2018.
- SILLA, J. et al. MIA-QSPR and effect of variable selection on the modeling of kinetic parameters related to activities of modified peptides against dengue type 2. **Chemometrics and Intelligent Laboratory Systems**, v. 108, p. 146-149, 2011.

SILVA, L.O.L.A. et al. Comparative assessment of feature selection and classification techniques for visual inspection of pot plant seedlings. **Computers and Electronics in Agriculture**, v. 97, p. 47-55, 2013.

SILVA, F. et al. Evaluating classification and feature selection techniques for honeybee subspecies identification using wing images. **Computers and Electronics in Agriculture**, v. 114, p. 68-77, 2015.

SUN, J. et al. Visualizing distribution of moisture content in tea leaves using optimization algorithms and NIR hyperspectral imaging. **Computers and Electronics in Agriculture**, v. 160, p. 153-159, 2019.

TAHERI-GARAVAND, A. et al. Real-time nondestructive monitoring of Common Carp Fish freshness using robust vision-based intelligent modeling approaches. **Computers and Electronics in Agriculture**, v. 159, p. 16-27, 2019.

TAN, P. N.; STEINBACH, M.; KUMAR, V. **Introduction to data mining**. Pearson Education India, 2016.

TEIMOURI, N. et al. A novel artificial neural networks assisted segmentation algorithm for discriminating almond nut and shell from background and shadow. **Computers and Electronics in Agriculture**, v. 105, p. 34-43, 2014.

TOBER, M. PubMed, ScienceDirect, Scopus or Google Scholar–Which is the best search engine for an effective literature research in laser medicine?. *Medical Laser Application*, v. 26, n. 3, p. 139-144, 2011.

TORIMITSU, Set al. Sexual determination based on multidetector computed tomographic measurements of the second cervical vertebra in a contemporary Japanese population. **Forensic Science International**, v. 266, p. 588.e1-588.e6, 2016.

ULRICI, A. et al. Efficient chemometric strategies for PET–PLA discrimination in recycling plants using hyperspectral imaging. **Chemometrics and Intelligent Laboratory Systems**, v. 122, p. 31–39, 2013.

UNAY, D. et al. Automatic grading of Bi-colored apples by multispectral machine vision. **Computers and Electronics in Agriculture**, v. 75, p. 204-212, 2011.

WESTERHUIS, J. et al. Assessment of PLS-DA cross validation. **Metabolomics**, v. 4, p. 81-89, 2008.

XIAOBO, Z. et al. Variables selection methods in near-infrared spectroscopy. **Analytica chimica acta**, v. 667, p. 14-32, 2010.

YU, Q. et al. Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. **Photogrammetric Engineering & Remote Sensing**, v. 72, n. 7, p. 799-811, 2006.

ZHANG, M.; LI, C.; YANG, F. Classification of foreign matter embedded inside cotton lint using short wave infrared (SWIR) hyperspectral transmittance imaging. **Computers and Electronics in Agriculture**, v. 139, p. 75-90, 2017.

ZHANG, Y. et al. Automated spectral feature extraction from hyperspectral images to differentiate weedy rice and barnyard grass from a rice crop. **Computers and Electronics in Agriculture**, v. 159, 2019.

### **3 Segundo Artigo: A novel approach for the identification of most relevant tablet regions in the image detection of falsified medicines**

**Fábio do Prado Puglia**

**Michel José Anzanello**

#### **Abstract**

In this paper, we propose a novel image based approach to detect falsified medicines and identify the most relevant regions of the tablet in the task of classification. The framework is based on the propositions of Bernart *et al.* (2016). The original input images undergo an initial pre-processing step, which (i) removes the background to find the region of interest, (ii) clusters individual pixels into super-pixels, and (iii) extracts features containing color and texture information. The classification task is conducted over the set of super-pixels using a Support Vector Machine (SVM) classifier, and the class prediction of all super-pixels belonging to each image is used to define the class the respective image will be inserted into. The task of identifying the relevant regions is performed using the concept of support vectors, generating a heatmap that indicates the regions that contribute the most to the classification task. Two datasets containing authentic and falsified samples of Cialis and Viagra medicines were used to validate our propositions by achieving correct classification rates of 100% on both datasets. Regarding the task of identifying the most relevant regions, our proposition outperformed the traditional LIME (Local Interpretable Model-agnostic Explanations) method by yielding more robust explanations.

**Keywords:** image analysis, supervised learning, classification, interpretable machine learning.

**O capítulo 3 apresenta um conteúdo muito semelhante ao artigo submetido a periódico.**

**Desta forma, com o intuito de evitar problemas referentes a direitos autorais, as páginas referentes ao capítulo 3 são omitidas desta versão da dissertação.**

## 4 Terceiro Artigo: Avaliação da qualidade de carne embalada apoiada em análise de imagens e ferramentas multivariadas

**Fábio do Prado Puglia**

**Michel José Anzanello**

### **Resumo**

A permanência longa de alimentos cárneos em ambientes refrigerados tende a alterar suas características de cor e textura, dentre outros, podendo comprometer suas condições para consumo. Este artigo propõe uma abordagem hierárquica para classificação da qualidade de carne bovina a partir de imagens em duas categorias que dizem respeito às condições para consumo de amostras do produto (classes ‘adequada’ ou ‘não-adequada’). O método, que é baseado na proposição de Bernart *et al.* (2016), submete as imagens originais a uma etapa de pré-processamento, de forma a remover o fundo, segmentar a imagem em sub-regiões e gerar novas variáveis com informações de cor e textura. As sub-regiões são utilizadas no treinamento de pares de classificadores, combinados de forma hierárquica. Para cada imagem, a classe é determinada pela proporção de sub-regiões atribuídas à classe ‘não-adequada’, comparando-se esta proporção com diferentes pontos de corte. A proposição foi validada em seis conjuntos de dados contendo diferentes tipos de animais e embalagem, apresentando taxa correta de classificação de 90% ou superior. O método foi comparado com a proposições originais de Bernart *et al.* (2016), e apresentou sistematicamente desempenho superior nas métricas acurácia, sensibilidade e especificidade.

**Palavras-chave:** análise de imagem, aprendizado supervisionado, classificação hierárquica.

### **Abstract**

The long stay of meat food in refrigerated environments tends to alter its characteristics of color and texture, which may compromise its consumption conditions. This article proposes a hierarchical approach to classify beef quality from images in two categories that relate to the

conditions for consumption of product samples ('suitable' or 'unsuitable' classes). The method, which is based on the proposition of Bernart *et al.* (2016), submits the original images to a pre-processing step to remove the background, segment the image into sub-regions and generate new variables with color and texture information. The subregions are used to fit pairs of classifiers combined hierarchically. For each image, the class is determined by computing the proportion of sub-regions assigned to the 'unsuitable' class, comparing this proportion with different thresholds. The proposition was validated in six datasets containing different types of animals and packaging, presenting 90% or higher accuracy. The method was compared with the original propositions of Bernart *et al.* (2016) and systematically showed superior performance in the metrics accuracy, sensitivity, and specificity.

**Keywords:** image analysis, supervised learning, hierarchical classification.

#### 4.1 Introdução

A carne faz parte de um conjunto de alimentos dietéticos básicos que contêm grandes proporções de proteínas facilmente digeríveis, gordura altamente calórica, vitaminas e outros micronutrientes. O consumo moderado de carne como parte de uma dieta balanceada contribui significativamente para a ingestão de nutrientes essenciais, especialmente no caso de pessoas em grupo de risco, como idosos e gestantes (BIESALSKI, 2005; MCAFEE *et al.*, 2010). Os aumentos da população e de seu poder de compra impulsionam o consumo agregado de carne, especialmente em países em desenvolvimento, como Indonésia e China (WHITNALL; PITTS, 2019). Para garantir o padrão de qualidade demandado por consumidores, a indústria da carne precisa compreender fatores que influenciam na percepção de qualidade pelo consumidor, exigindo a adoção de ferramentas e processos que conduzam a altos padrões de qualidade (HENCHION *et al.*, 2014). Neste contexto, técnicas computacionais de análise de imagens (visão computacional) combinadas a métodos de aprendizado de máquina fornecem meios de administrar esta tarefa.

Visão computacional consiste em uma tentativa de substituir o processo visual humano de tomada de decisão por um sistema automático (DU *et al.*, 2006). O sistema geralmente baseia-se em um computador que emprega técnicas de aprendizado para identificar automaticamente relações significativas a partir de dados de treinamento. Ao generalizar os padrões aprendidos, a

abordagem fornece predições que contribuem para a interpretação de dados novos. Visão computacional apresenta-se como estratégia eficaz para a identificação da qualidade de carnes quando fundamentada na utilização de informações de cor e textura. Estes dois atributos, além de odor, caracterizam-se como os principais fatores associados ao processo de deterioração da carne, o qual é consequência, entre outras, da proliferação microbiana e de processos enzimáticos e oxidativos (AHMED *et al.*, 2017; MANCINI; HUNT, 2005). Tais processos de degradação da qualidade ocorrem em diversas etapas do processo de produção, como preparação, distribuição e armazenamento, de maneira que o último, mais precisamente a forma de embalagem, é um dos principais determinantes do tempo de validade da carne (WOJNOWSKI, 2017).

Diversas combinações de técnicas foram desenvolvidas com o intuito de investigar a qualidade da carne. Arsalane *et al.* (2018) utilizaram imagens no espaço HSI (*Hue, Saturation, Intensity*), acopladas aos algoritmos *Principal Component Analysis* (PCA) e *Support Vector Machine* (SVM), para prever em tempo real o grau de frescor de contrafilés. Os autores armazenaram as amostras em caixas plásticas, e obtiveram uma taxa de classificação correta de 100% com o SVM. El Barbri *et al.* (2014) adotaram uma abordagem similar com imagens nos espaços de cores *RGB* (*Red, Green, Blue*) e *HSI* alimentando algoritmos de redes neurais artificiais na predição de qualidade de carne embalada em caixas plásticas. Taxas de classificação correta na faixa de 95% foram obtidas. A mesma tarefa foi conduzida por Li *et al.* (2016), que exploraram um sistema de espalhamento de luz para aquisição de imagens e recorreram a informações de textura; naqueles experimentos *Linear Discriminant Analysis* (LDA) e SVM conduziram a desempenhos de 100%. A recorrência da utilização de SVM na literatura está em linha com as tendências previstas para sistemas de aprendizado de visão computacional em aplicações de avaliação de qualidade de alimentos (DU *et al.*, 2006). Tais tendências também apontam a combinação de diferentes técnicas de aprendizado em um sistema único como uma estratégia promissora neste tipo de tarefa.

Neste artigo, propõe-se uma abordagem hierárquica para identificação do estado de conservação de contrafilés bovinos armazenados em diferentes embalagens com base em características visuais, como cor e textura. O método apoia-se na proposição de Bernart *et al.* (2016), com a qual compartilha a utilização de informações de cor e textura, extraídas das imagens em uma etapa inicial de pré-processamento. Na sequência, e como proposição original, a

abordagem combina pares de classificadores de forma hierárquica, maximizando a taxa de classificação correta. Sob o ponto de vista teórico, a utilização da combinação de dois algoritmos diferentes com o intuito de aumentar o desempenho da tarefa de classificação apoia-se no conceito de *trade-off* entre flexibilidade e erro de classificação (HASTIE *et al.*, 2009). Espera-se que a incorporação de um classificador adicional à abordagem tradicional de classificação resulte no aumento dos graus de liberdade da fronteira de decisão, podendo resultar em melhor ajuste do modelo aos dados e aumento do desempenho de classificação.

A proposição foi validada num conjunto de dados constituído por seis tipos de combinação de carne e embalagem. Os resultados foram comparados com as proposições originais de Bernart *et al.* (2016) nas mesmas imagens. A abordagem proposta resultou em desempenho superior em todos os tipos de carne e embalagem quando avaliadas métricas como acurácia, sensibilidade e especificidade. Além do aspecto teórico, a estrutura metodológica proposta contribui sob perspectiva prática ao fornecer uma abordagem rápida e confiável de verificação da qualidade de carne via coleta de imagens com celular e posterior análise das imagens através de aplicativo, com aplicabilidade *in loco* por agentes sanitários e de fiscalização. O método leva em consideração dois tipos de embalagens comumente utilizadas para armazenamento - vácuo e Policloreto de Vinila (PVC) - o que garante a proximidade entre a proposição e aplicações reais.

A sequência deste artigo é organizada da seguinte forma: a seção 4.2 detalha os dados e métodos utilizados na análise. A seção 4.3 apresenta os resultados da abordagem proposta, comparando-os com os resultados obtidos pela abordagem tradicional e desenvolvendo as respectivas discussões. Por fim, as conclusões são apontadas na seção 4.4.

## **4.2. Materiais e Métodos**

### **4.2.1 Dados**

Amostras de carne bovina foram adquiridas em um abatedouro na região metropolitana de Belo Horizonte. As amostras são oriundas de três tipos diferentes de animal: gado fêmea, gado macho e gado castrado, todos com três anos de idade. Para cada tipo de animal, dois tipos de embalagem foram utilizados para o armazenamento das carnes: a vácuo e PVC. As embalagens a

vácuo conservam melhor a condição da carne, de forma que carnes com este tipo de embalagem têm sua validade estimada em 15 dias, quando mantidas a uma temperatura inferior a 4°C (CODEX ALIMENTARIUS, 1997; BRASIL, 1996). Por sua vez, as embalagens de PVC mantêm a validade da carne até o terceiro dia (BRASIL, 2011). As amostras foram armazenadas em uma geladeira a 5°C. Diariamente, foram coletadas imagens das amostras através de uma impressora com resolução de 1200 dpi (Impressora Multifuncional Epson Stylus Office, TX300F). Para as amostras embaladas a vácuo, foram coletadas 31 imagens, com prazo entre corte e coleta variando de zero a 30 dias. Para as amostras embaladas com PVC, foram feitas 11 imagens, com prazo entre zero e 10 dias. O conjunto final de imagens é composto por 125 imagens de seis tipos diferentes: fêmea PVC, macho PVC, castrado PVC, fêmea vácuo, macho vácuo, castrado vácuo. Por fim, a variável tempo de prateleira (prazo, em dias, entre evento de corte e captura da imagem) foi categorizada, gerando duas classes: carne ‘adequada’ (referente a tempo de prateleira de 0 a 3 dias, para amostras do tipo PVC, e 0 a 15 dias, para amostras do tipo vácuo) e carne ‘não-adequada’ (referente a tempo de prateleira de 4 a 10 dias, para amostras do tipo PVC, e 16 a 30 dias, para amostras do tipo vácuo). As categorias foram geradas com base na opinião de especialistas de processo. A Figura 4.1 apresenta dois exemplos ilustrativos das imagens.



Figura 4.1 – Imagens das amostras de contrafilés

## 4.2.2 Fundamentação teórica das técnicas multivariadas de classificação

### 4.2.2.1 SVM

SVM é um método de aprendizado supervisionado para classificação. O objetivo é encontrar um hiperplano que defina a fronteira de decisão, maximizando suas margens e separando as amostras de treinamento pertencentes a diferentes classes (BOSER *et al.*, 1992). Usando o artifício do *kernel* para transformar dados de entrada em uma representação de alta dimensão, o SVM é aplicado a problemas não lineares. Seja o conjunto de dados de treinamento  $\{x_i, y_i\}$ ,  $i = 1, \dots, N$ , onde  $x_i$  é o  $i$ -ésimo vetor de características e  $y_i$  é o rótulo para a  $i$ -ésima observação. SVM resolve um problema de programação quadrática (PLATT, 1998), dado pela equação (4.1):

$$\arg \min_{w,b} \frac{1}{2} \|W\|^2 + C \sum_{i=1}^N \xi_i \quad (4.1)$$

Sujeito à restrição apresentada na equação (4.2):

$$y_i(x_i \cdot w + b) - 1 + \xi_i \geq 0 \quad \forall i \quad (4.2)$$

A variável de folga  $\xi_i$  é introduzida para permitir alguns erros de classificação quando o problema não é linearmente separável. A quantidade de erros permitidos é controlada pelo parâmetro de regularização  $C$ , que afeta a capacidade de generalização do SVM. A solução para o problema acima fornece o hiperplano de separação, definido por  $(wT.X + b) = 0$ , onde  $w$  é o vetor normal ao hiperplano e  $b$  é o termo de interceptação. A solução depende apenas dos vetores de suporte (*support vectors*), as instâncias de treinamento  $x_i$  para as quais  $w_i$  é diferente de zero. Os vetores de suporte são as observações próximas ao limite da classe, para as quais as restrições na equação (4.2) são atendidas.  $W$  é representado apenas em termos dos vetores de suporte (CORTES; VAPNKI, 1995; HASTIE *et al.*, 2009).

### 4.2.2.2 RF

*Random Forest* (RF) é um algoritmo que combina múltiplas árvores de decisão, agregadas para calcular a predição numa tarefa de classificação ou regressão através da maioria dos valores preditos pelas árvores individuais. Na construção de cada árvore de decisão, um número aleatório de variáveis é selecionado, ao mesmo tempo em que uma porção aleatória dos dados é filtrada no processo de re-amostragem (BREIMAN, 2001). Esta abordagem leva a vantagens como

capacidade de aplicação eficiente em bancos de dados grandes e com elevado número de variáveis. A flexibilidade da fronteira de decisão permite obter elevado desempenho, enquanto que o caráter aleatório do algoritmo reduz o risco de ocorrência de sobre-ajuste aos dados (*overfitting*) e aumenta a capacidade de generalização. Os dois principais hiper-parâmetros referentes ao RF são o número total de árvores de decisão a serem treinadas e o número de variáveis a serem selecionadas aleatoriamente no treinamento de cada árvore (PETERS *et al.*, 2007).

Além dos propósitos de classificação e predição, RF pode ser utilizado na tarefa de seleção de variáveis. O algoritmo *Random Forest-Recursive Feature Elimination* (RF-RFE) combina RF com o método de seleção *Recursive Feature Elimination* (RFE), o qual ordena as variáveis de acordo com alguma medida de importância (GRANITO *et al.*, 2006). O método inicia com o conjunto completo de variáveis e, a cada iteração, elimina a variável que apresenta menor medida de importância. A ordem de eliminação das variáveis define a ordenação final das variáveis, de forma inversamente proporcional. No caso de RF-RFE, a medida de importância é dada por RF, estima a importância de uma variável ao inserir a mesma no algoritmo e avaliar o impacto desta alteração no desempenho do modelo. A premissa é que variáveis mais relevantes têm bastante impacto no desempenho, enquanto o oposto vale para as menos relevantes.

#### 4.2.2.3 KNN

O algoritmo KNN (*K-Nearest Neighbors*) é um método de aprendizado baseado em instâncias, dado que constrói a hipótese diretamente a partir dos dados de treinamento. Apresenta uma lógica simples, classificando cada observação de acordo com a classe mais comum entre seus *k* vizinhos mais próximos (RUSSELL; NORVIG, 2002). Nesta tarefa, uma métrica de distância é necessária para identificar a proximidade entre os pontos, sendo a distância Euclidiana a mais utilizada (ALFEILAT *et al.*, 2019). O único hiper-parâmetro do algoritmo é o número de vizinhos mais próximos a serem considerados na classificação.

#### 4.2.3 Abordagem proposta

A abordagem proposta compartilha a primeira etapa com as proposições de Bernart *et al.* (2016). Nesta etapa, ocorre um pré-processamento das imagens originais, com remoção de fundo e identificação da região de interesse, agrupamento de pixels, e extração de variáveis. Na segunda etapa, conduz-se a classificação para diferenciar amostras ‘adequadas’ das ‘não-adequadas’.

Enquanto Bernart *et al.* (2016) fazem isso através de classificadores tradicionais, a abordagem proposta utiliza uma combinação hierárquica de classificadores. A Figura 4.2 apresenta a estrutura do método proposto, cujas etapas são descritas em maiores detalhes nas próximas seções.

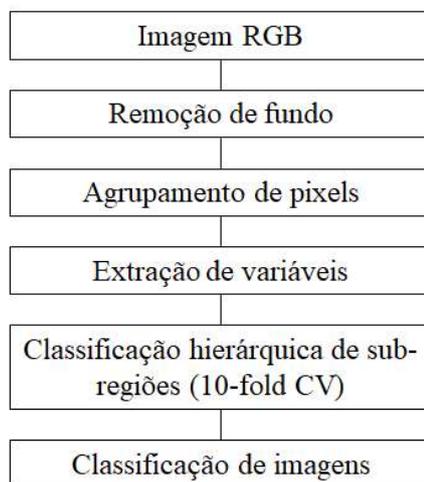


Figura 4.2 – Estrutura da abordagem proposta

#### 4.2.3.1 Pré-processamento de imagem

##### 4.2.3.1.1 Remoção do fundo e identificação de região de interesse

A primeira etapa da tarefa de pré-processamento, na qual ocorre remoção de fundo e identificação da região de interesse, é composta por três principais passos: inicialização, processamento e refinamento. A inicialização tem como objetivo gerar uma pré-segmentação da imagem original, de forma a separar as regiões de carne das regiões de fundo. O passo inicia com o cálculo do canal de variabilidade de intensidade local ( $I$ ), o qual depende da definição da imagem normalizada de luminância  $L$  (média dos três canais de entrada RGB) e da variabilidade de intensidade  $\tau(x, y, \sigma)$ , definida conforme equação (4.3).

$$\tau(x, y, \sigma) = \bar{L}(x, y) \frac{\hat{H}(x, y, \sigma)}{H(x, y, \sigma)} \quad (4.3)$$

onde  $H(x, y, \sigma) = L(x, y) * G(\sigma)$  (ou seja, a imagem de luminância  $L$  é filtrada por  $G(\sigma)$ , um filtro Gaussiano com desvio padrão  $\sigma$ ), e  $\hat{H}(x, y, \sigma)$  é o complemento de  $H(x, y, \sigma)$ .  $\tau(x, y, \sigma)$  é calculado para diferentes valores de  $\sigma$ , e apenas seu valor máximo é selecionado em cada pixel.

O canal de variabilidade de intensidade  $\tau$  é então normalizado, resultando em  $I(x, y)$ . Por fim, a pré-segmentação da imagem é obtida pela aplicação do método de Otsu (OTSU, 1979) no canal  $I$ , selecionando a maior região como referente à carne.

Com base na pré-segmentação do canal  $I$ , procede-se para a etapa de processamento de segmentação, na qual se estima a similaridade de cada pixel em relação à área de carne e à área de fundo. Inicialmente, definem-se os vetores de densidade referentes à carne e ao fundo, respectivamente  $C^C$  e  $C^F$ . Na sequência, seja  $S^C$  o conjunto de pixels pertencentes à área de pré-segmentação de carne, e  $S^F$  o conjunto de pixels pertencentes à área de pré-segmentação do fundo. A matriz  $C$ , que representa as intensidades médias de pixels do espaço de cores dentro das áreas de carne e fundo, pode ser computada de acordo com equação (4.4):

$$\tilde{C} = \begin{bmatrix} C^C \\ C^F \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^{\#S^C} D(S_{i,x}^C, S_{i,y}^C) / \#S^C \\ \sum_{i=1}^{\#S^F} D(S_{i,x}^F, S_{i,y}^F) / \#S^F \end{bmatrix} \quad (4.4)$$

onde  $S_{i,x}$  e  $S_{i,y}$  são as coordenadas do  $i$ -ésimo elemento do conjunto de pixels  $S$  nos eixos  $x$  e  $y$ , respectivamente, e  $\#S$  representa a cardinalidade de  $S$ .  $D$  é o vetor de densidade de cor de um pixel, e pode ser representado pela equação (4.5):

$$D_{x,y} = [-\log(I_1^C(x, y)), -\log(I_2^C(x, y)), -\log(I_3^C(x, y))]^T \quad (4.5)$$

onde  $I_i^C(x, y)$  é a intensidade RGB normalizada de determinado pixel  $(x, y)$ . Uma vez determinada a matriz  $C$ , pode-se calcular a probabilidade de um pixel  $(x, y)$  ter características de região de carne ou fundo, como mostra a equação (4.6):

$$[I^C(x, y), I^F(x, y)] = \tilde{C}^{-1} L(x, y) - E \quad (4.6)$$

onde  $E = \min_{x,y}(\tilde{C}^{-1} L(x, y))$ .  $I^C$  e  $I^F$  são dois canais novos contendo estimativas locais: o canal de informação de carne e o canal de informação de fundo.

Para manter os valores no intervalo  $[0, 1]$  e para facilitar a visualização, os dois canais  $I^C$  e  $I^F$  são normalizados. Um filtro Gaussiano é aplicado nos canais  $I^C$  e  $I^F$  – com dimensões  $7 \times 7$  e  $\sigma = 1$ , como sugerido por Bernart *et al.* (2016) – para reduzir a influência de pixels ruidosos.

Definidos os canais de informações  $I^C$  e  $I^F$ , utiliza-se o método de Otsu para gerar as segmentações. O canal  $I^C$  é o que identifica a carne, então pixels neste canal que apresentam

valores acima do limite definido pelo método são atribuídos à área de carne. Analogamente, pixels no canal  $I^F$  com valores abaixo do limite são atribuídos à área de fundo.

A terceira etapa realiza o refinamento da segmentação, visando aprimorar a fronteira que define a região da carne. Utiliza-se o método de contornos ativos de Chan-Vese (CHAN *et al.*, 2000), tomando como entrada as máscaras de segmentação geradas na etapa anterior, e obtendo fronteiras definitivas. Seja  $I_i$  ( $i = 1, 2, 3$ ) a imagem constituída de duas regiões de intensidades constantes  $c_1$  e  $c_2$  (referentes às regiões de carne e fundo, respectivamente), e  $C$  a curva separando as regiões. A partir de uma estimativa da região da carne, o método Chan-Vese minimiza a função de energia  $F(c_1, c_2, C)$  aplicada sobre  $I_i$ , conforme equação (4.7):

$$F(c_1, c_2, C) = \mu \text{length}(C) + \lambda_1 \int_{\text{inside}(C)} \frac{1}{3} \sum_{i=1}^3 |I_i(x, y) - c_{1,i}|^2 dx dy + \lambda_2 \int_{\text{outside}(C)} \frac{1}{3} \sum_{i=1}^3 |I_i(x, y) - c_{2,i}|^2 dx dy \quad (4.7)$$

onde  $\mu$ ,  $\lambda_1$  e  $\lambda_2$  são os parâmetros referentes aos pesos. A cada iteração  $n$ , as constantes  $c_{1,i}$  e  $c_{2,i}$  são atualizadas. O processo se repete até que o critério de parada seja atingido, seja a estabilidade ou número máximo de iterações. Caso a curva  $C$  apresente regiões menores fechadas fora das bordas da região da carne, apenas a região maior é selecionada, e um preenchimento de cavidades é executado.

#### 4.2.3.1.2 Agrupamento de pixels

Definida a região de interesse, um algoritmo de agrupamento de pixels é aplicado de forma a criar sub-regiões visualmente similares. Esta etapa reduz a dimensionalidade das instâncias analisadas, uma vez que desloca o foco da análise de pixels individuais para grandes agrupamentos de pixels. Bernart *et al.* (2016) propuseram a incorporação, no presente método, do algoritmo SLIC (*Simple Linear Iterative Clustering*), proposto por Achanta *et al.* (2012). O algoritmo visa agrupar os pixels em regiões visualmente similares, gerando uma malha que se adapta às particularidades da imagem. O número de clusters gerados é definido por  $k$ , único parâmetro do algoritmo. SLIC é uma adaptação do conhecido  $k$ -means, apresentando duas principais diferenças: (i) o cálculo da distância entre pixels considera apenas pixels de uma região com as mesmas dimensões do cluster que se quer obter, consequentemente reduzindo esforço

computacional na etapa de otimização; e (ii) a métrica utilizada para o cálculo da distância combina informações de proximidade espacial com informações de cores.

#### 4.2.3.1.3 Extração de variáveis

Na última etapa do pré-processamento das imagens, ocorre a extração das variáveis a serem utilizadas na tarefa de classificação. O objetivo é gerar dois conjuntos de variáveis: um com informações locais, representando as características visuais de cada sub-região, e outro com informações de contexto, relacionadas à imagem ao qual cada região pertence. O conjunto de variáveis locais é representado por  $\varphi = \{L, a, b, t1, t2, t3, m1, m2, m3\}$ , onde  $\{L, a, b\}$  são os valores originais dos pixels no espaço de cores CIELAB,  $\{t1, t2, t3\}$  referem-se à variabilidade de textura e  $\{m1, m2, m3\}$  representam a magnitude do gradiente nos canais  $t1, t2$  e  $t3$ . O vetor  $\varphi$  é calculado para cada pixel, e a sumarização do mesmo em relação ao conjunto de pixels da sub-região  $s_i$  resulta no vetor de variáveis locais  $E_{local}(\varphi, s_i)$ , o qual representa informações de cor e textura referente à sub-região  $s_i$ . As métricas utilizadas na sumarização são média, mediana, mínimo e máximo para os vetores  $\{L, a, b, t1, t2, t3\}$ , e média, variância, mínimo e máximo para o vetor  $\{m1, m2, m3\}$ . O resultado é um conjunto com 36 variáveis locais (9 variáveis x 4 métricas).

O conjunto de variáveis contextuais tem como objetivo diferenciar sub-regiões pertencentes a contextos diferentes. O conjunto é composto por seis variáveis calculadas com base nos canais  $t1, t2$  e  $t3$  nos pixels dentro da região de interesse:  $\{media\_grad\_t1, media\_grad\_t2, media\_grad\_t3\}$  contêm informações sobre a média da magnitude dos canais  $t1, t2$  e  $t3$ , enquanto  $\{var\_grad\_t1, var\_grad\_t2, var\_grad\_t3\}$  referem-se à variância da magnitude dos mesmos canais.

#### 4.2.3.2 Abordagem proposta para classificação hierárquica

Após a etapa de pré-processamento, o conjunto de dados apresenta-se no formato tabular, no qual cada instância representa uma sub-região de imagem e, cada coluna, uma variável extraída. Os dados são separados por tipo de animal e embalagem, resultando em seis subconjuntos de observações (fêmea PVC, macho PVC, castrado PVC, fêmea vácuo, macho vácuo, castrado vácuo).

A abordagem hierárquica conduz inicialmente à classificação das sub-regiões, e, posteriormente, à predição da classe de cada imagem, usando a proporção de sub-regiões preditas em cada classe. No primeiro momento, são utilizados três classificadores (SVM, RF e KNN), combinados dois-a-dois, o que gera uma variedade de seis pares de modelos. Os classificadores que compõem o par são denominados, genericamente, como Classificador<sub>1</sub> e Classificador<sub>2</sub>. A ordem de utilização dos classificadores é relevante, de forma que a combinação que utiliza SVM e RF como Classificador<sub>1</sub> e Classificador<sub>2</sub>, respectivamente, é diferente da combinação que utiliza RF e SVM respectivamente como Classificador<sub>1</sub> e Classificador<sub>2</sub>.

Na etapa de inicialização, executa-se RF-RFE para seleção de variáveis, definindo-se dois subconjuntos com as 10 e 30 melhores variáveis – denominados Subconjunto<sub>10</sub> e Subconjunto<sub>30</sub> (os tamanhos dos subconjuntos foram definidos com base na opinião de especialistas de processo). A estes dois, adicionam-se três subconjuntos referentes a: apenas variáveis locais (Subconjunto<sub>LOCAL</sub>), apenas variáveis de contexto (Subconjunto<sub>CONTEXTO</sub>), e totalidade de variáveis (Subconjunto<sub>TOTAL</sub>).

As etapas 1 a 6 descritas a seguir repetem-se para cada combinação de subconjunto de variáveis e par de classificadores. O número total de combinações possíveis é 30, dado que existem cinco subconjunto de variáveis (Subconjunto<sub>10</sub>, Subconjunto<sub>30</sub>, Subconjunto<sub>LOCAL</sub>, Subconjunto<sub>CONTEXTO</sub> e Subconjunto<sub>TOTAL</sub>) e seis pares de classificadores (SVM+RF, RF+SVM, SVM+KNN, KNN+SVM, RF+KNN e KNN+RF).

Etapa 1 – São construídos e validados os classificadores Classificador<sub>1</sub> e Classificador<sub>2</sub>, com validação cruzada (*10-fold cross-validation*) e explorando diferentes valores de hiper-parâmetros. Selecionam-se as configurações de Classificador<sub>1</sub> e Classificador<sub>2</sub> correspondentes aos menores erros de validação.

Etapa 2 – Para a melhor configuração de cada classificador, computam-se três informações para todas as observações do conjunto de dados: as predições de classe do Classificador<sub>1</sub> (Predição<sub>CLASSIFICADOR1</sub>) e do Classificador<sub>2</sub> (Predição<sub>CLASSIFICADOR2</sub>) e a probabilidade predita para classe ‘não-adequada’ fornecida apenas pelo Classificador<sub>2</sub> (Predição%<sub>NAO</sub>).

Etapa 3 – As instâncias do conjunto de dados são ordenadas de acordo com a variável Predição%<sub>NAO</sub>, de forma crescente. O conjunto de dados ordenado é dividido então em cinco partes iguais (o primeiro grupo é composto por 20% das observações que receberam, do

Classificador<sub>1</sub>, menor probabilidade de pertencer à classe ‘não-adequada’, enquanto o quinto grupo é composto por 20% das observações que receberam, do Classificador<sub>1</sub>, maior probabilidade de pertencer à classe ‘não-adequada’).

Etapa 4 – Para cada um dos cinco grupos, compara-se a predição de classe fornecida pelo Classificador<sub>1</sub> (Predição<sub>CLASSIFICADOR1</sub>) com a classe real de cada observação, obtendo-se a taxa de classificação correta dada pelo Classificador<sub>1</sub> (variável denominada Acurácia<sub>CLASSIFICADOR1</sub>, sumariada para cada grupo através da média simples).

Etapa 5 – O valor de predição final a ser utilizado para cada observação do conjunto de dados é definido pela seguinte regra: se observação pertence a um grupo com Acurácia<sub>CLASSIFICADOR1</sub>  $\geq$  80%, usar predição do Classificador<sub>1</sub> (Predição<sub>CLASSIFICADOR1</sub>); caso contrário, usar predição do Classificador<sub>2</sub> (Predição<sub>CLASSIFICADOR2</sub>). A escolha do valor 80% como ponto de corte (assim como a definição do número de partes a dividir as observações na etapa 3) ocorreu após condução de experimentos e análise de sensibilidade.

Etapa 6 – Por fim, definidas as classes preditas para cada sub-região, calcula-se, para cada imagem, a proporção de sub-regiões preditas como classe ‘não-adequada’ (variável Proporção<sub>NAO</sub>). Definindo um ponto de corte (Proporção<sub>LIMITE</sub>) e variando o mesmo de 5% a 95%, com 5% de incremento, atribui-se uma imagem à classe ‘não-adequada’ se Proporção<sub>NAO</sub>  $\geq$  Proporção<sub>LIMITE</sub>. Adota-se o valor de Proporção<sub>LIMITE</sub> que maximiza a taxa de classificação correta.

### 4.3. Resultados e Discussões

As etapas de pré-processamento de imagens foram executadas no software Matlab R2018b (Mathworks, EUA), rodando em um computador Intel® Core™ i7-5500U de 8GB. As demais etapas (seleção de variáveis e classificação de sub-regiões e imagens) foram executadas no mesmo computador utilizando a linguagem de programação livre R.

Os subconjuntos de variáveis obtidos na etapa de seleção de variáveis são detalhados na Tabela 4.1. As variáveis de contexto com informações de textura dominam os dois conjuntos, indicando que o processo de decomposição da carne está associado a alterações na textura da mesma. Além disso, o fato de as variáveis de contexto apresentarem maior relevância pode ser

uma consequência da forma como o processo de decomposição da carne ocorre (homogeneamente no pedaço, e não de forma localizada). Esta verificação é corroborada na análise da Figura 4.3, que põe lado-a-lado duas imagens em etapas opostas do processo de decomposição, ambas referentes ao tipo fêmea com embalagem de PVC. A imagem do lado esquerdo representa uma amostra capturada no dia do corte, enquanto o lado direito apresenta uma amostra referente ao décimo dia após o corte. A primeira apresenta tons mais vivos de vermelho, enquanto a segunda, vermelho mais escuro. Em ambas, entretanto, a coloração é homogênea em toda a superfície do contrafilé (exceto nas regiões de gordura).

Tabela 4.1 – Subconjuntos de variáveis gerados com RF-RFE

<b>Subconjuntos gerados via RF-RFE</b>			
<b>Subconjunto<sub>10</sub></b>	<b>Subconjunto<sub>30</sub></b>		
<b>media_grad_t1</b>	<b>var_grad_t1</b>	<b>m2_min</b>	<b>Gh_media</b>
<b>var_grad_t2</b>	<b>var_grad_t2</b>	<b>m2_mediana</b>	<b>L_mediana</b>
<b>var_grad_t1</b>	<b>media_grad_t1</b>	<b>Gh_mediana</b>	<b>a_min</b>
<b>var_grad_t3</b>	<b>var_grad_t3</b>	<b>a_mediana</b>	<b>t1_media</b>
<b>media_grad_t3</b>	<b>media_grad_t2</b>	<b>t2_mediana</b>	<b>Rh_media</b>
<b>media_grad_t2</b>	<b>media_grad_t3</b>	<b>a_media</b>	<b>Bh_min</b>
<b>b_min</b>	<b>b_min</b>	<b>Bh_media</b>	<b>m3_mediana</b>
<b>b_median</b>	<b>b_media</b>	<b>t1_mediana</b>	<b>L_media</b>
<b>b_mean</b>	<b>b_mediana</b>	<b>a_max</b>	<b>Rh_mediana</b>
<b>b_max</b>	<b>b_max</b>	<b>t2_media</b>	<b>Gh_min</b>

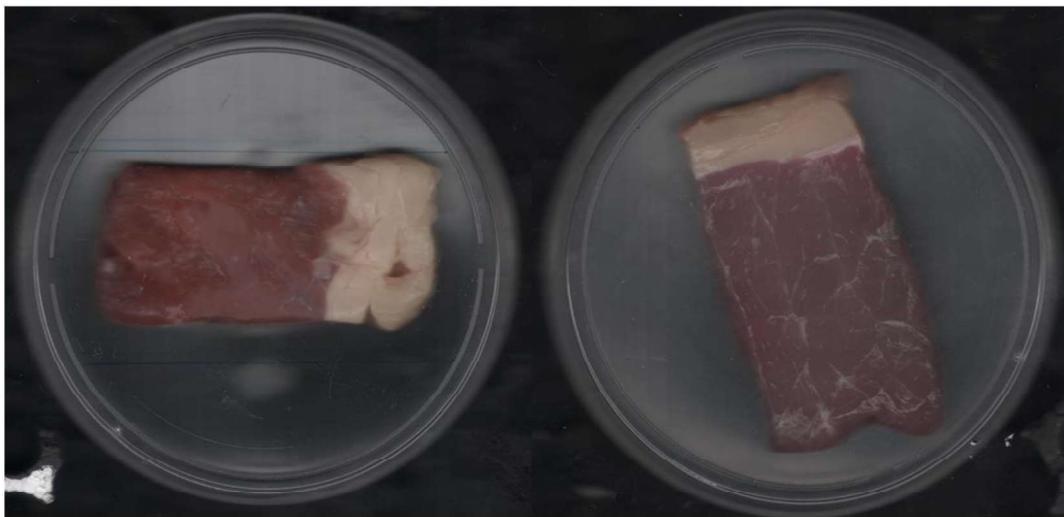


Figura 4.3 – Comparação de cores no contrafilé para as classes ‘adequada’ e ‘não-adequada’. Painel esquerdo: imagem de fêmea PVC capturada no dia do corte. Painel direito: imagem de fêmea PVC capturada 10 dias após o corte.

A Tabela 4.2 apresenta o desempenho de classificação da abordagem proposta, para cada conjunto de dados analisado. Para o cálculo das métricas sensibilidade e especificidade, a classe ‘não-adequada’ foi considerada como condição positiva, e a ‘adequada’ como negativa.

O melhor desempenho foi obtido com imagens de animal fêmea em embalagem de PVC, nas quais as métricas taxa de classificação correta, sensibilidade e especificidade atingiram valores iguais a 100%. Os demais conjuntos de dados apresentam acurácia entre 90% e 90,91%. Cinco dos seis conjuntos apresentam especificidade de 100%, indicando que a abordagem executa com sucesso a identificação de classe ‘adequada’. A exceção é ‘fêmea vácuo’, que classificou erroneamente uma observação da classe ‘adequada’ como ‘não-adequada’, resultando na especificidade de 93,33%. De forma geral, os erros de classificação concentram-se no tipo falso negativo, resultando em observações da classe ‘não-adequada’ sendo classificadas indevidamente como classe ‘adequada’ em 13% a 17% dos casos.

Tabela 4.2 – Desempenho da abordagem proposta para a tarefa de classificação

<b>Conjunto</b>	<b>Acurácia</b>	<b>Sensibilidade</b>	<b>Especificidade</b>
Castrado PVC	90,91%	87,50%	100,00%
Castrado Vácuo	90,32%	83,33%	100,00%
Fêmea PVC	100,00%	100,00%	100,00%
Fêmea Vácuo	90,00%	86,67%	93,33%
Macho PVC	90,91%	87,50%	100,00%
Macho Vácuo	90,32%	83,33%	100,00%

A Tabela 4.3 traz as combinações de classificadores que geraram o melhor desempenho para cada conjunto de dados. O classificador SVM está presente em todos os conjuntos, mas a posição do SVM na hierarquia de classificadores varia, aparecendo como Classificador<sub>1</sub> em ‘castrado PVC’, ‘castrado vácuo’ e ‘fêmea vácuo’, e como Classificador<sub>2</sub> em ‘fêmea PVC’, ‘macho PVC’ e ‘macho vácuo’. Além disso, observa-se que o ponto de corte  $Proporção_{LIMITE}$  apresenta uma grande variação entre os diferentes conjuntos. Enquanto no conjunto ‘macho PVC’, por exemplo, as imagens são atribuídas à classe ‘não-adequada’ se a proporção de sub-regiões nesta classe for igual ou superior a 15%, no conjunto ‘fêmea PVC’ esta proporção é de 45%. A variação observada nos valores deste parâmetro corrobora a hipótese de que o mesmo pode ser um fator determinante no desempenho de classificação, e que adotar a estratégia padrão de atribuir as observações à classe com maior probabilidade pode não ser a melhor opção.

Tabela 4.3 – Pares de classificadores com melhores desempenhos

<b>Dataset</b>	<b>Classificador<sub>1</sub></b>	<b>Classificador<sub>2</sub></b>	<b>Proporção<sub>LIMITE</sub></b>
Castrado PVC	SVM	RF	35,00%
Castrado Vácuo	SVM	KNN	20,00%
Fêmea PVC	KNN	SVM	45,00%
Fêmea Vácuo	SVM	KNN	40,00%
Macho PVC	RF	SVM	15,00%
Macho Vácuo	KNN	SVM	20,00%

Por fim, a abordagem proposta é comparada com as proposições originais de Bernart *et al.* (2016), cujos resultados são exibidos na Tabela 4.4. De forma sistemática, a abordagem proposta (hierárquica) obteve desempenho superior na tarefa de classificação, apresentando um crescimento na taxa de classificação correta de pelo menos 8% (90,00% contra 83,33% no conjunto ‘fêmea vácuo’) e até 25% (90,91% contra 72,73% no conjunto ‘macho PVC’). Desempenho superior também é observado nas métricas sensibilidade e especificidade, com ganhos de até 37,5% e 28,57%, respectivamente. O ganho de desempenho observado na abordagem proposta está de acordo com o esperado, uma vez que a ação de adicionar um segundo algoritmo resulta em um aumento de flexibilidade do classificador, expandindo a variedade de formas que podem representar a fronteira de decisão. A utilização de dados de teste na mensuração do desempenho garante que não se incorra em excessivo ajuste do classificador aos dados.

Tabela 4.4 – Desempenhos da abordagem de Bernart *et al.* (2016) e abordagem proposta

Conjunto	Resultados da proposição de Bernart <i>et al.</i> (2016)				Resultados da abordagem proposta		
	Acurácia	Sensibilidade	Especificidade	Classificador	Acurácia	Sensibilidade	Especificidade
Castrado PVC	81,82%	50,00%	100,00%	SVM	90,91%	87,50%	100,00%
Castrado Vácuo	80,65%	81,25%	80,00%	RF	90,32%	83,33%	100,00%
Fêmea PVC	90,91%	75,00%	100,00%	RF	100,00%	100,00%	100,00%
Fêmea Vácuo	83,33%	87,50%	78,57%	SVM	90,00%	86,67%	93,33%
Macho	72,73%	75,00%	71,43%	KNN	90,91%	87,50%	100,00%
Macho Vácuo	80,65%	81,25%	80,00%	SVM	90,32%	83,33%	100,00%

#### 4.4 Conclusões

A combinação de visão computacional e técnicas de aprendizado de máquina conduz com sucesso a identificação da qualidade de carnes, baseada na exploração de alguns dos principais fatores associados ao processo de deterioração da carne, como cor e textura. Este artigo propõe uma abordagem de classificação com o intuito de identificar a qualidade de conservação de contrafilés bovinos.

A abordagem proposta combina múltiplos classificadores em pares, de forma hierárquica. Uma etapa de pré-processamento é inicialmente empregada para converter as imagens originais em conjuntos de sub-regiões de interesse com informações de cor e textura. Os pares de

classificadores conduzem então a tarefa de classificação das sub-regiões, e a classe das imagens é determinada com base na predição das sub-regiões. O método foi aplicado em seis conjuntos de imagens de contrafilé, contendo diferentes tipos de animais e embalagens, resultando em desempenhos de classificação de pelo menos 90% e até 100%. A proposição foi comparada com uma abordagem de referência, e apresentou desempenho superior em todos os conjuntos.

Apesar dos resultados promissores apresentados, a abordagem proposta contém limitações. O processo de captura das imagens exige alguns cuidados para que as imagens obtidas estejam adequadas. Os principais pontos de atenção são distância e orientação das amostras em relação à câmera, assim como a iluminação artificial, necessária em ambientes escuros. A identificação da região de interesse pode apresentar dificuldades nos casos em que não há clara distinção entre objeto investigado e fundo da imagem.

Desenvolvimentos futuros incluem aprimoramentos na etapa de seleção de variáveis, como a incorporação de métodos adicionais para concorrer com o utilizado atualmente. Outro potencial desenvolvimento é a adoção de número maior de classificadores, em combinações de três ou quatro algoritmos. Além disso, a inclusão de uma etapa para tratar desbalanceamento de classes apresenta grande potencial de contribuição, dado o desequilíbrio de proporção entre as classes nos conjuntos de embalagem PVC.

#### 4.5 Referências

ACHANTA, R. et al. SLIC Superpixels Compared to State-of-the-Art Superpixel Methods. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 34, n. 11, p. 2274-2282, 2012.

AHMED, I. et al. A comprehensive review on the application of active packaging technologies to muscle foods. **Food Control**, v. 82, p. 163-178, 2017.

AHMED, I. et al. An overview of smart packaging technologies for monitoring safety and quality of meat and meat products. **Packaging Technology and Science**, v. 31, n. 7, p. 449-471, 2018.

ALFEILAT, A. et al. Effects of distance measure choice on k-nearest neighbor classifier performance: a review. **Big data**, v. 7, n. 4, p. 221-248, 2019.

ARSALANE, A. et al. An embedded system based on DSP platform and PCA-SVM algorithms for rapid beef meat freshness prediction and identification. **Computers and Electronics in Agriculture**, v. 152, p. 385-392, 2018.

BIESALSKI, H. K. Meat as a component of a healthy diet—are there any risks or benefits if meat is avoided in the diet?. **Meat science**, v. 70, n. 3, p. 509-524, 2005.

BOSER, B. E.; GUYON, I. M.; VAPNIK, V. N. A training algorithm for optimal margin classifiers. **Proceedings of the fifth annual workshop on Computational learning theory**, 1992.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. PORTARIA Nº 304, DE 22 DE ABRIL DE 1996. **Diário Oficial da União**. Disponível em: <<https://www.defesa.agricultura.sp.gov.br/legislacoes/portaria-mara-304-de-22-04-1996,691.html>>. Acesso em: 06 março 2021.

BRASIL. Agência Nacional de Vigilância Sanitária. Portaria nº 2619, de 06 de dezembro de 2011. Aprova o Regulamento de Boas Práticas e de controle de Condições Sanitárias Técnicas. D.O.U. - **Diário Oficial da União; Poder Executivo**, de 06 de dezembro de 2011. Disponível em: <[https://www.prefeitura.sp.gov.br/cidade/secretarias/upload/chamadas/portaria\\_2619\\_1323696514.pdf](https://www.prefeitura.sp.gov.br/cidade/secretarias/upload/chamadas/portaria_2619_1323696514.pdf)>. Acesso em: 06 mar. 2021.

BREIMAN, L. Random forests. **Machine learning**, v. 45, n. 1, p. 5-32, 2001.

CHAN, T. F.; SANDBERG, B. Y.; VESE, L. A. Active contours without edges for vector-valued images. **Journal of Visual Communication and Image Representation**, v. 11, n. 2, p.130-141, 2000..

DRAFT CODE OF HYGIENIC PRACTICE FOR REFRIGERATED PACKAGED FOODS WITH EXTENDED SHELF LIFE. **CODEX ALIMENTARIUS**. 1997. Disponível em: <<http://www.fao.org/3/w7429e/w7429e0r.htm>>. Acesso em 06 março 2021.

CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, v. 20, p. 273–297, 1995.

DU, C. J.; SUN, D. W. Learning techniques used in computer vision for food quality evaluation: a review. **Journal of food engineering** v. 72, n. 1, p. 39-55, 2006.

EL BARBRI, N.; HALIMI, A.; RHOFIR, K. A nondestructive method based on an artificial vision for beef meat quality assesement. **International Journal of Innovative Research In Electrical, Electronics, Instrumentation and Control Engeineering**, v. 2, p. 2060-2063, 2014.

GRANITTO, P. M. et al. Recursive feature elimination with random forest for PTR-MS analysis of agroindustrial products. **Chemometrics and intelligent laboratory systems**, v. 83, n. 2, p. 83-90, 2006.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The elements of statistical learning: data mining, inference, and prediction**. Springer Science & Business Media, 2009.

HENCHION, M. et al. Meat consumption: Trends and quality matters. **Meat science**, v. 98, n. 3, p. 561-568, 2014.

- LI, H. et al. Feasibility study on nondestructively sensing meat's freshness using light scattering imaging technique. **Meat science**, v. 119, p. 102-109, 2016.
- MANCINI, R. A.; HUNT, M. Current research in meat color. **Meat science**, v. 71, n. 1, p. 100-121, 2005.
- MCAFEE, A. J. et al. Red meat consumption: An overview of the risks and benefits. **Meat science**, v. 84, n. 1, p.1-13, 2010.
- OTSU, N. A threshold selection method from gray-level histograms. **IEEE transactions on systems, man, and cybernetics**, v. 9, n. 1, p.62-66, 1979.
- PETERS, J. et al. Random forests as a tool for ecohydrological distribution modelling. **Ecological modeling**, v. 207, n. 2-4, p.304-318, 2007.
- PLATT, J. Sequential minimal optimization: A fast algorithm for training support vector machines, 1998.
- RUSSELL, S.; NORVIG, P. **Artificial intelligence: a modern approach**, 2002.
- SHIRANITA, K.; MIYAJIMA, T.; TAKIYAMA, R. Determination of meat quality by texture analysis. **Pattern Recognition Letters**, v. 19, n. 14, p.1319-1324, 1998.
- WHITNALL, T.; PITTS, N. Global trends in meat consumption. **Agricultural Commodities**, v. 9, n. 1, p. 96, 2019.
- WOJNOWSKI, W. et al. Electronic noses: Powerful tools in meat quality assessment. **Meat science**, v. 131, p.119-131, 2017.

## 5 Considerações finais

Neste capítulo, são apresentadas as conclusões do trabalho, associadas aos objetivos declarados inicialmente. Ao final, são propostos potenciais desdobramentos futuros.

### 5.1 Conclusões

O principal objetivo do presente trabalho consistiu em propor novas abordagens que utilizem visão computacional e aprendizado de máquina para identificar falsificações de medicamentos e detecção de qualidade de carne. Este objetivo foi decomposto em diversos objetivos específicos: *(i)* investigar as principais técnicas de seleção de variáveis utilizadas em combinação com análise de imagens, com foco na contribuição para o processo de detecção de alimentos; *(ii)* identificar oportunidades de novas combinações de métodos de seleção de variáveis e aplicações no contexto de detecção de alimentos; *(iii)* identificar as regiões visualmente relevantes na tarefa de classificação de medicamentos falsificados; *(iv)* comparar o desempenho da abordagem proposta para identificação das regiões relevantes com desempenho da abordagem de referência; e *(v)* comparar o desempenho da abordagem para identificação da qualidade com o desempenho da abordagem de referência.

Os dois primeiros objetivos foram alcançados no primeiro artigo, no qual foram estudadas as técnicas de seleção de variáveis em aplicações de detecção de alimentos. Neste estudo, as diferentes combinações de técnicas e aplicações foram distribuídas de forma esquemática, fornecendo a visão geral do assunto e permitindo a identificação de oportunidades de novas combinações.

Os objetivos *(iii)* e *(iv)* foram atingidos no segundo artigo. A abordagem proposta foi dividida em duas etapas. A primeira apoiou-se num pré-processamento das imagens originais para dividi-las em sub-regiões e convertê-las em informações de cor e textura. Um classificador SVM foi utilizado para prever as classes das sub-regiões, e, a partir desta predição, a classe das imagens foi determinada. O método obteve sucesso nesta tarefa, com taxa de classificação correta de 100% em dois conjuntos de dados. A segunda etapa da proposição fundamentou-se no conceito dos vetores de suporte, com o intuito de identificar as regiões dos comprimidos mais relevantes na tarefa de classificação. O mapa de calor gerado pelo método permite identificar

visualmente as regiões mais relevantes no comprimido. A sistemática foi comparada com um método de referência, apresentando resultados mais robustos.

Por fim, o último objetivo foi alcançado no terceiro artigo. A abordagem proposta neste artigo utiliza uma etapa inicial de pré-processamento análoga à utilizada no segundo artigo. Após esta etapa, as sub-regiões geradas na etapa anterior são classificadas através de uma sistemática hierárquica que combina dois classificadores, permitindo posteriormente a predição da classe das imagens. A validação do método em seis conjuntos diferentes de dados permitiu a obtenção de resultados superiores a 90%, 83,33% e 93,33% para acurácia, sensibilidade e especificidade, respectivamente. Em um dos conjuntos de dados, o valor das três métricas foi de 100%. De forma sistemática, a abordagem proposta superou a abordagem de referência utilizada para comparação.

## 5.2 Sugestões para trabalhos futuros

As pesquisas seguintes são sugeridas como extensões das proposições apresentadas na dissertação:

- adoção de uma sistemática robusta de seleção de variáveis como uma etapa anterior à etapa de classificação;

- incorporação de mais classificadores à abordagem de classificação hierárquica, permitindo-se obter maior poder de generalização e melhores resultados em conjuntos de dados diferentes;

- implementação de uma análise de sensibilidade do erro de teste ao grau de flexibilidade, avaliando a relação entre as duas grandezas e determinando o grau de flexibilidade que gera o menor erro de teste; e

- adoção de técnicas para tratar desbalanceamento de classe, de forma a minimizar os efeitos de possíveis diferenças entre as proporções de classes.