



**UNIVERSIDADE ESTADUAL DE CAMPINAS**  
**FACULDADE DE ENGENHARIA DE ALIMENTOS**

**IRENE MARIVEL NOLASCO PÉREZ**

**“CARACTERIZAÇÃO E IDENTIFICAÇÃO DE CARNE DE AVES POR MÉTODOS  
NÃO-DESTRUTIVOS”**

**“CHARACTERIZATION AND IDENTIFICATION OF POULTRY MEAT BY NON-  
DESTRUCTIVE TECHNIQUES”**

**CAMPINAS**  
**2019**

**Irene Marivel Nolasco Pérez**

**“CARACTERIZAÇÃO E IDENTIFICAÇÃO DE CARNE DE AVES POR MÉTODOS  
NÃO-DESTRUTIVOS”**

**“CHARACTERIZATION AND IDENTIFICATION OF POULTRY MEAT BY NON-  
DESTRUCTIVE TECHNIQUES”**

Tese apresentada à Faculdade de Engenharia de Alimentos  
da Universidade Estadual de Campinas como parte dos  
requisitos exigidos para a obtenção do título de Doutora em  
Engenharia de Alimentos

Thesis presented to the Faculty of Food Engineering of the  
State University of Campinas in partial fulfillment to the  
requirements for the degree of Doctor, in the Food  
Engineering

**Orientador: Prof. Dr. Douglas Fernandes Barbin**

**ESTE TRABALHO CORRESPONDE À  
VERSÃO FINAL DA TESE DEFENDIDA PELA  
ALUNA IRENE MARIVEL NOLASCO PEREZ,  
E ORIENTADA PELO PROF. DR. DOUGLAS  
FERNANDES BARBIN**

**CAMPINAS  
2019**

Ficha catalográfica  
Universidade Estadual de Campinas  
Biblioteca da Faculdade de Engenharia de Alimentos  
Claudia Aparecida Romano - CRB 8/5816

Nolasco Pérez, Irene Marivel, 1973-  
N712c      Caracterização e identificação de carne de aves por métodos não-  
destrutivos / Irene Marivel Nolasco Pérez. – Campinas, SP : [s.n.], 2019.

Orientador: Douglas Fernandes Barbin.  
Tese (doutorado) – Universidade Estadual de Campinas, Faculdade de  
Engenharia de Alimentos.

1. Imagem hiperespectral. 2. Tecnologia analítica de processos. 3.  
Espectroscopia no infravermelho próximo. 4. Análise estatística multivariada. 5.  
Aprendizado de máquina. 6. Quimiometria. I. Barbin, Douglas Fernandes. II.  
Universidade Estadual de Campinas. Faculdade de Engenharia de Alimentos.  
III. Título.

Informações para Biblioteca Digital

**Título em outro idioma:** Characterization and identification of poultry meat by non-destructive methods

**Palavras-chave em inglês:**

Hyperspectral imaging  
Process analytical technology  
Near infrared spectroscopy  
Multivariate statistical analyses  
Machine learning  
Chemometrics

**Área de concentração:** Engenharia de Alimentos

**Titulação:** Doutora em Engenharia de Alimentos

**Banca examinadora:**

Douglas Fernandes Barbin [Orientador]

Carmen Josefina Contreras Castillo

Daniela Souza Ferreira

Elza Louka Ida

Juliana Aparecida Fracarolli

**Data de defesa:** 12-04-2019

**Programa de Pós-Graduação:** Engenharia de Alimentos

**Identificação e informações acadêmicas do(a) aluno(a)**

- ORCID do autor: <https://orcid.org/0000-0001-6412-5417>

## **COMISSÃO EXAMINADORA**

---

Prof. Dr. Douglas Fernandes Barbin  
ORIENTADOR – DEA/FEA/UNICAMP

---

Prof. Dra. Carmen Josefina Contreras Castillo  
MEMBRO TITULAR – ESALQ/USP

---

Prof. Dr. Sérgio Bertelli Bfanzer Júnior  
MEMBRO TITULAR – DTA/FEA/UNICAMP

---

Prof. Dra. Elza Iouko Ida  
MEMBRO TITULAR – (CCA/UEL)

---

Prof. Dra. Juliana Aparecida Fracarolli  
MEMBRO TITULAR – (FEAGRI/UNICAMP)

A ata da defesa com as respectivas assinaturas dos membros encontra-se no SIGA/Sistema de fluxo de Tese e na secretaria do Programa da Unidade.

## **DEDICATORIA**

Dedico este trabalho a Deus porque, tudo provém dele e “Porque dele e por ele, e para ele são todas as coisas; glória a ele eternamente. Amém”

Romanos 11:36

Aos meus, que Deus me deu, como o mais apreciado deste mundo, minha família, a meus pais Vicente e Maura, a meus irmãos Jesus, Julio, Wilson e Carmen, a minhas sobrinhas e sobrinho, porque eles são a minha inspiração

## **AGRADECIMENTOS**

A Deus por meio de Jesus Cristo, por ser meu Senhor e Salvador e melhor amigo, por ser tudo na minha vida, porque ele é a vida eterna, pela saúde, cuidado em toda esta caminhada e por fortalecer-me nos momentos difíceis, muito obrigada por olhar para mim ainda que não mereça, por minha família e amigos.

A meus pais pelo apoio incondicional, sobretudo à minha mãe pelos ensinamentos para toda a vida, por ensinar-me a não desistir dos sonhos, por ser exemplo de fortaleza e por todo seu apoio; a meu pai pelo que aprendi de você, a dar valor às pequenas coisas, a meus irmãos Jesús, Julio, Wilson e Carmen, pelos conselhos nos momentos precisos, pelo carinho de vocês, respeito e consideração e pela ajuda nos momentos difíceis.

Às minhas sobrinhas especialmente a Luciana pela ajuda e meu sobrinho os quais são a razão de seguir adiante, para eles, continuarem com o exemplo e pelo carinho de vocês.

À Faculdade de Engenharia de Alimentos – UNICAMP pela oportunidade de fazer o doutorado e continuar crescendo profissionalmente com a realização deste trabalho.

Ao Professor Douglas Fernandes Barbin, por aceitar me orientar, pelo apoio incondicional, e toda sua orientação no desenvolvimento neste trabalho, pela amizade, pela paciência.

A todos os professores pelos ensinamentos recebidos durante a permanência na UNICAMP, sobretudo, aos Professores Flavio e Eduardo os primeiros na UNICAMP, que não duvidaram em falar um sim, para mim, pela confiança, ensinamentos, e amizade.

Aos Professores Marise e Sergio pelo todo o apoio na realização neste trabalho com as matérias primas, com seus aportes, sugestões, etc.

Aos professores de Londrina, Ana, Sylvio pelo trabalho realizado em conjunto e a professora Elisa pela hospedagem nessa cidade.

À Comissão examinadora pelas correções que contribuíram a enriqueceram este trabalho.

A todo o pessoal nos diferentes Laboratórios de Engenharia de Alimentos: a Patty, Vanessa, Zildene, pela disposição de sempre ajudar em especial ao pessoal do laboratório de Inovação de Alimentos, a todo grupo de LINA muito obrigada a todos vocês por todo o compartilhado.

Ao pessoal do Laboratório de Carnes e Derivados em especial a Jose Roberto pela disposição de ensinar as análises físico-químicas, e sua disposição de sempre ajudar.

Ao pessoal do Laboratório do grupo de Instrumentação e automação em Química Analítica

(GIA) do instituto de Química (IQ) em especial a Cristiane pela amabilidade e gentileza.

A todo o pessoal da UNICAMP, de Limpeza, bibliotecários, docentes, pessoal da secretaria da FEA e do DEA, especialmente à Cosme, Fredy e Reynaldo, pela atenção, carinho.

Aos irmãos em Cristo que o Senhor me deu deste país, muito grata a todos desde o mais pequenininho especialmente à avó Ilda, pelas brincadeiras as quais convertiam as minhas tristezas em alegria, pelo carinho, conversas, convite, as caronas, os sorrisos, as lágrimas, as fotos, as viagens, as caminhadas, as confidências, os abraços, as orações, as comidas, cada um de vocês estão dentro do meu coração, que o Senhor recompense tudo o que cada um de vocês fizeram por mim. Sentirei saudade de vocês, mas a esperança é que um dia nos reencontraremos no céu, o lindo céu e estaremos juntos pela eternidade.

Às família Reynalt Medina e Lopez Benites por suas orações, por seu carinho e amizade.

A todos os colegas e amigos da Engenharia de Alimentos, em especial Juan Felipe e José Luis, aos quais considero como irmãos, e à Lina por seu carinho e amizade ainda que já não estejam aqui, mas sempre estarão no meu coração. A todos os amigos que compartilharam seu tempo, confidências conversas, sorrisos, amizade, abraços, cumprimentos, entre outros pelas conversas desde que chegue ao Brasil e tudo quanto compartilhamos.

Aos amigos de outras faculdades e outros países por nossas conversas, e compartilhar nossas culturas, e nossa amizade, Rita, Emanuela, Alma, Marriam, Manuela, Amelia, Cheng Lee, Freda, Ebenezer, Tami, Shamila, Claudio e Arlem pela viagem que você me deu.

À casa J6A pelo apoio, acolhimento, carinho e por tudo o compartilhado durante a permanência nesse lugar, Karina, Cristina, Aline, Natalia, Rafaela, Fernanda, Gyl e Bia, vocês foram a família que Deus me deu no Brasil, amo a vocês com o amor de Deus.

A todos os amigos de Peru que sempre estão aí quando estou lá, muito obrigada por sua amizade e carinho que perdura até hoje, apesar do tempo e distancia.

A todos os que contribuíram de uma maneira ou outra da culminação deste trabalho, em especial aos que contribuíram desinteressadamente.

A todo o Brasil pela oportunidade de estudar, Deus abençoe este país mais e mais.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

MUITO OBRIGADA A TODOS VOCÊS, DEUS ABENÇOE MUITO

Porque o Senhor dá a sabedoria; da sua boca é que vem o conhecimento e o entendimento.

Provérbios 2:6

Ó Senhor, quão variadas são as tuas obras! Todas as coisas fizeste com sabedoria; cheia está a terra das tuas riquezas.

Salmos 104:24

Com ele está a sabedoria e a força; conselho e entendimento tem.

Jó 12:13

Quão melhor é adquirir a sabedoria do que o ouro! e quão mais excelente é adquirir a prudência do que a prata!

Provérbios 16:1

Não há sabedoria, nem inteligência, nem conselho contra o Senhor.

Provérbios 21:3

E ele muda os tempos e as estações; ele remove os reis e estabelece os reis; ele dá sabedoria aos sábios e conhecimento aos entendidos.

Daniel 2:21

Não te fatigues para enriqueceres; e não apliques nisso a tua sabedoria.

Provérbios 23:4

Porque a sabedoria deste mundo é loucura diante de Deus; pois está escrito: Ele apanha os sábios na sua própria astúcia.

1 Coríntios 3:9

E, demais disto, filho meu, atenta: não há limite para fazer livros, e o muito estudar é enfado da carne.

Eclesiastes 12:12

A lei do Senhor é perfeita, e refrigera a alma; o testemunho do Senhor é fiel, e dá sabedoria aos simplices.

Salmos 19:7

Pois, que aproveitaria ao homem ganhar Todo o mundo e perder a sua alma?

Marcos 8:36

Se tudo o que aprendemos não contribui para conservar o meio ambiente e para serem melhores pessoas, continuaremos sendo ignorantes.

## RESUMO

Atualmente a espectroscopia no infravermelho próximo (*NIR*) é utilizada na indústria agro-alimentar como uma técnica analítica não destrutiva, por ser rápida e dispensar a utilização de reagentes. Similarmente, a visão computacional tem encontrado diversas aplicações em processos industriais de alimentos. O objetivo no presente estudo foi caracterizar e identificar a carne de frango por métodos não destrutivos como as técnicas de espectroscopia no infravermelho próximo (*NIR* portátil e imagem hiperespectral (*NIR-HSI*)), e imagem digital *RGB* (*RGB-I*). Num primeiro trabalho, se utilizaram 130 amostras inteiras e 90 amostras moidas de diferentes partes de frango (peito, sobrecoxa e coxa). Atributos físicos e químicos (características de cor, pH e  $L^* a^* b^*$ ) e composição química (proteína, gordura, umidade e cinzas) foram determinados para cada amostra (moidas e inteiras). Foram utilizados métodos de análise multivariada como componentes principais (*PCA*), análise discriminante linear (*LDA*), e algoritmos de aprendizado de máquina como *Support Vector Machine* (*SVM*) e *Random Forest* (*RF*) para a classificação das amostras. Os dados espectrais foram adquiridos para o *NIR* portátil no intervalo de comprimento de onda entre 900 e 1700 nm. Os resultados confirmaram a possibilidade de diferenciar as amostras de peito, sobrecoxa e coxas com 97% de precisão. Num segundo trabalho, as técnicas espectroscópicas no infravermelho próximo (*NIR* portátil e imagem hiperespectral (*NIR-HSI*)), e imagem digital *RGB* (*RGB-I*) foram comparadas na identificação de 60 amostras de três diferentes espécies de carne (frango, suína e bovina) e detectar diferentes quantidades de mistura das amostras de carne frango com carne bovina e suína (210 amostras para a carne de frango misturado com carne bovina e 210 amostras para a carne de frango misturado com carne suína). Os dados espectrais foram adquiridos para o *NIR* portátil no intervalo de comprimento de onda entre 900 e 1700 nm, enquanto para as imagens hiperespectrais no *NIR* foram no intervalo 900 e 2500 nm e para as imagens *RGB* foram obtidos 59 parâmetros das imagens. Realizou-se *PCA* utilizando-se todas as variáveis e após seleção de variáveis latentes (*VL*), se realizou a *LDA* para classificar as amostras puras. Os dados espectrais brutos e pré-processados foram investigados separadamente como preditores dos modelos de regressão por mínimos quadrados parciais (*PLSR*). Utilizou as *VL* mais relevantes com a finalidade de otimizar o processamento de dados. Os melhores resultados foram com *NIR-HSI* e *RGB-I* ( $R^2_p = 0,92$ ,  $RPD = 3,82$ ,  $RER = 15,77$  e  $R^2_p = 0,86$ ,  $RPD = 2,66$ ,  $RER = 10,99$  respectivamente). Finalmente, conclui-se que essas técnicas classificaram e identificaram a carne de frango mostrando um grande potencial para utilização na indústria de processamento de carnes e por instituições que realizam inspeções de segurança e qualidade dos alimentos.

Palavras chaves: Imagem hiperespectral, tecnologia analítica de processos, quimiometria, espectroscopia no infravermelho próximo, análise estatística multivariada, aprendizado de máquina.

## ABSTRACT

Near-infrared (NIR) spectroscopy is currently used in the agriculture and food industry as a non-destructive, fast and reagentless analytical technique. Computer vision has also been applied to several food processes. The objective of the present study was to characterize and identify chicken meat by nondestructive methods such as near-infrared (NIR-HSI) spectroscopy and RGB (RGB-I) digital imaging. In the first study, 130 unground samples and 90 ground samples of different parts of chicken (breast, mound and thigh) were analysed. Physical and chemical attributes (pH and  $L^*a^*b^*$  color features) and chemical composition (protein, fat, moisture, and ash) were determined for each sample (minced and non-minced). Multivariate analyzes were used as principal components analysis (PCA), linear discriminant analysis (LDA), and machine learning algorithms such as Support Vector Machine (SVM) and Random Forest (RF) for the classification of samples. The portable NIR spectral data were acquired in the wavelength range between 900 and 1700 nm. The results confirmed the possibility of differentiating samples with 97% accuracy, proving the potential of this method to identify chicken cuts. In a second study, spectroscopic techniques in the near infrared (portable NIR and hyperspectral imaging (NIR-HSI)) and RGB digital imaging (RGB-I) were compared in the identification of 60 samples of three different species (chicken, pork, beef) and to detect different mixtures of chicken meat with beef and pork (210 samples for chicken meat mixed with beef and 210 samples of chicken meat mixed with pork). The spectral data were acquired for the portable NIR in the wavelength range between 900 and 1700 nm, while for the hyperspectral images in the NIR range were between 900 and 2500 nm and for the RGB images 59 image features were obtained. PCA was performed using all variables and after selection of latent variables (VL), the LDA was performed to classify the pure samples. Raw and preprocessed spectral data were investigated separately as predictors of the partial least squares regression (PLSR) models. In addition, the model used the most relevant VL to reduce the amount of data. Results of PLSR models were compared using the coefficient of determination for prediction ( $R^2_p$ ), ratio performance to deviation (RPD) and ratio of error range (RER). The best results were obtained with NIR-HSI and RGB-I ( $R^2_p = 0.92$ , RPD = 3.82, RER = 15.77 and  $R^2_p = 0.86$ , RPD = 2.66, RER = 10.99 respectively). Finally, it is concluded that these techniques classified and identified chicken meat, showing great potential for use in the meat processing industry and by institutions conducting food safety and quality inspections.

**Keywords:** Hyperspectral imaging, process analytical technology, chemometrics, near infrared spectroscopy, multivariate statistical analyses, machine learning.

## LISTA DE FIGURAS

|                                                                                                                                                                                                                                                                                                                                                                                                  |    |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 1. Diagrama de fluxo da parte experimental da tese .....                                                                                                                                                                                                                                                                                                                                  | 26 |
| Figura 2. Diagrama de fluxo do processamento. ....                                                                                                                                                                                                                                                                                                                                               | 27 |
| Figura 3. Esquema da decomposição por <i>PCA</i> .....                                                                                                                                                                                                                                                                                                                                           | 46 |
| Figure 1. Raw and second derivate mean spectrum of chicken meatNIR .....                                                                                                                                                                                                                                                                                                                         | 69 |
| Figure 2. PCA. scores of breast, drumsticks, and thigh for (a) minced and (b) non- minced samples .....                                                                                                                                                                                                                                                                                          | 47 |
| Figure 1. Average spectra of ground meat samples from beef, pork and chicken 235 acquired by: a) portable NIR spectrometer; b) NIR hyperspectral imaging system.....                                                                                                                                                                                                                             | 82 |
| Figure 2. PCA. scores for ground samples of different species: (a) PCA for full spectra acquired by portable NIR spectrometer; (b) PCA for three 239 selected wavelengths from NIR spectrometer; (c) PCA for all features from RGB-I; (d) PCA for three selected features from RGB-I; (e) PCA for 240 full spectra acquired by NIR-HSI; (f) PCA for three wavelengths selected from NIR-HIS..... | 83 |
| Figure 3. PCA loadings plot for ground samples of different species (a) spectra 244 acquired by portable NIR spectrometer; (b) spectra acquired by NIR-HSI.....                                                                                                                                                                                                                                  | 84 |
| Figure 4. Prediction map of ground chicken samples adulterated with different percentages of beef .....                                                                                                                                                                                                                                                                                          | 89 |

## LISTA DE TABELAS

|                                                                                                                                                      |    |
|------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Tabela 1 - Consumo de frango no Brasil e no mundo (1000 TM) .....                                                                                    | 33 |
| Tabela 2 - Produção de carne de frango (1000 TM).....                                                                                                | 34 |
| Tabela 3 - Composição da carne de frango .....                                                                                                       | 34 |
| Tabela 4 - Porcentagem do tipo de gordura .....                                                                                                      | 35 |
| Table 1. Physicochemical analysis of chicken parts .....                                                                                             | 68 |
| Table 2. Algorithm accuracy among LDA, RF, SVM, and SVM <sup>t</sup> models, comparison between minced and non-minced samples .....                  | 70 |
| Table 3. Confusion matrix of LDA, RF, SVM, and SVM <sup>t</sup> classification model of non-minced samples of validation set with pretreatment ..... | 71 |
| Table 1. Results for PLSR models for chicken samples adulterated with pork .....                                                                     | 86 |
| Table 2. Results for PLSR models for chicken samples adulterated with beef .....                                                                     | 87 |
| Table 3. Results for PLSR models with selected features for chicken samples adulterated with beef and pork .....                                     | 88 |

## LISTA DE ABREVIATURAS E SIGLAS

**CLS** - Mínimos quadrados clássicos (*Classical least square*),

**FIR** - Infravermelho distante (*Far infrared*),

**GA** - Algoritmo genético (*Genetic algorithm*),

**HSV** - Valor da saturação de matiz (*Hue saturation value*),

**ILS** - Inversos mínimos quadrados (*Quadrados mínimos inverso*),

**k-NN** - Vizinhos mais próximos (*k-nearest neighbors*),

**LDA** - Análises discriminante linear (*Linear discriminant analysis*),

**ML** - Aprendizado de máquina (*machine learning*),

**MIR** - Infravermelho médio (*Mid Infrared*),

**NIPALS** - Mínimos quadrados parciais não-interativo (*Nonlinear interactive partial least square*),

**NIR** - Infravermelho próximo (*Near infrared*),

**NIR-HSI** - Imagem hiperespectral no infravermelho próximo (*Near infrared hyperspectral imaging*),

**PCA** - Análise de componentes principais (*Principal component analysis*),

**PC** - Componentes principais (*Principal components*),

**PCR** - Regressão de componentes principais (*Principal component regression*),

**PLS** - Mínimos quadrados parciais (*Partial least squares*),

**PLSR** - Regressão de mínimos quadrados parciais (*Partial least squares regression*),

**$R^2$**  - Coeficiente de determinação (*Coefficient of determination*),

**$R^2_c$**  - Coeficiente de determinação para calibração (*Coefficient of determination for calibration*),

**$R^2_{cv}$**  - Coeficiente de determinação para validação cruzada (*Coefficient of determination for cross-validation*),

**$R^2_p$**  - Coeficiente de calibração de predição (*Coefficient of prediction*),

**RER** - Razão de intervalo de erro (*Ratio of error range*),

**RF** - Floresta aleatória (*Random forest*)

**RGB** - Vermelho, verde, azul (*Red, green, blue*),

**RGB - I-** Imagem em Vermelho, verde e azul-Imagem, (*Red, green, blue – image*),

**RMSEC** - Erro quadrático médio de calibração (*Root mean squared error of calibration*),

**RMSECV** - Erro quadrático médio de validação cruzada (*Root mean square error of cross-validation*),

**RMSEP** - Erro quadrático médio de predição (*Root mean square error of prediction*),

**ROI** - Região de interesse (*Region of interest*),

**RPD** - Relação de desempenho do desvio (*Ratio performance to deviation*),

**SIMCA** - Modelamento suave independente de analogia de classes (*Soft independent modelling of class analogy*),

**SNV**- Variação normal padrão (*Standard normal variate*),

**SVM** - Máquina de vector de suporte (*Support vector machine*),

**TM** - Tonelada métrica (*metric ton*);

**TVC** - Determinação de contagem total viável (*Total viable count*),

**UVE** - Eliminação de variáveis não informativas (*Uninformative variables elimination*),

**VL** - Variáveis latentes (*Latent variables*).

## Sumário

|                                                                                   |    |
|-----------------------------------------------------------------------------------|----|
| <b>CAPÍTULO 1</b> .....                                                           | 20 |
| <b>INTRODUÇÃO GERAL, OBJETIVOS E ESTRUTURA DA TESE</b> .....                      | 20 |
| 1. Introdução .....                                                               | 21 |
| 2. Objetivos .....                                                                | 24 |
| 2.1. OBJETIVO GERAL .....                                                         | 24 |
| 2.2. OBJETIVOS ESPECÍFICOS .....                                                  | 24 |
| 3. ESTRUTURA DA TESE .....                                                        | 24 |
| <b>CAPÍTULO 2</b> .....                                                           | 32 |
| <b>REVISÃO DA LITERATURA</b> .....                                                | 32 |
| 2. REVISÃO DA LITERATURA .....                                                    | 33 |
| 2.1. Materia Prima .....                                                          | 33 |
| 2.1.1. Composição química da carne de aves .....                                  | 34 |
| 2.1.2. Abate de frango e desossa da carcaça .....                                 | 35 |
| 2.1.3. Tipos de fibra nos cortes de Frango .....                                  | 36 |
| 2.1.4. Classificação de carnes e técnicas de autenticidade de carne .....         | 37 |
| 2.2. Espetroscopia no infravermelho próximo ( <i>NIR</i> ) .....                  | 39 |
| 2.2.1. Modos de medição .....                                                     | 39 |
| 2.2.1.1. Transmitância .....                                                      | 39 |
| 2.2.1.2. Reflectância .....                                                       | 40 |
| 2.2.1.3. Transmitância difusa .....                                               | 40 |
| 2.2.2. Equipamento .....                                                          | 40 |
| 2.2.3. Aplicações de espectroscopia no infravermelho próximo ( <i>NIR</i> ) ..... | 40 |
| 2.3. Imagem digital .....                                                         | 42 |
| 2.3.1. Processamento de imagens digitais .....                                    | 42 |
| 2.4. Imagem hiperespectral .....                                                  | 42 |
| 2.5. Quimiometria .....                                                           | 42 |

|                                                                                                                          |    |
|--------------------------------------------------------------------------------------------------------------------------|----|
| 2.5.1. Pré-tratamento dos dados.....                                                                                     | 44 |
| 2.5.2. Métodos de reconhecimentos de padrões não supervisionados.....                                                    | 46 |
| 2.5.2.1. Análise de componentes principais .....                                                                         | 46 |
| 2.5.2.2. Regressão por mínimos quadrados parciais ( <i>PLS</i> ) .....                                                   | 49 |
| 2.5.3. Métodos de classificação ou reconhecimentos de padrões supervisionados .....                                      | 49 |
| 2.5.3.1. Análises Discriminante Linear ( <i>LDA</i> ) .....                                                              | 49 |
| 2.5.3.2. Modelamento suave independente de analogia de classes ( <i>SIMCA</i> ).....                                     | 50 |
| 2.6. Aprendizado de Máquina ( <i>ML - Machine Learning</i> ).....                                                        | 52 |
| 2.6.1. Floresta Aleatoria ( <i>RF -Random Forest</i> ) .....                                                             | 51 |
| 2.6.2. Máquina de vetores de suporte ( <i>SVM - Support Vector Machine</i> ) .....                                       | 52 |
| <b>CAPÍTULO 3</b> .....                                                                                                  | 62 |
| <b>CLASSIFICATION OF CHICKEN PARTS USING A PORTABLE NEAR-INFRARED (NIR) SPECTROPHOTOMETER AND MACHINE LEARNING</b> ..... | 62 |
| Abstract.....                                                                                                            | 66 |
| Introduction.....                                                                                                        | 66 |
| Material and methods .....                                                                                               | 67 |
| Samples.....                                                                                                             | 67 |
| NIR Spectroscopy.....                                                                                                    | 67 |
| Physicochemical Attributes and Chemical Composition .....                                                                | 67 |
| Data Processing and Machine Learning (ML) .....                                                                          | 68 |
| Results and Discussion .....                                                                                             | 68 |
| Physicochemical Analysis .....                                                                                           | 68 |
| Near-Infrared (NIR) Analysis.....                                                                                        | 68 |
| Preliminary Investigation Using Principal Component Analysis (PCA) .....                                                 | 69 |
| Machine Learning (ML) Classification .....                                                                               | 69 |
| Conclusion.....                                                                                                          | 71 |
| Acknowledgments .....                                                                                                    | 71 |
| References .....                                                                                                         | 71 |

|                                                                                           |    |
|-------------------------------------------------------------------------------------------|----|
| <b>CAPÍTULO 4</b> .....                                                                   | 71 |
| <b>COMPARISON OF RAPID TECHNIQUES FOR CLASSIFICATION OF GROUND MEAT</b> .....             | 71 |
| <b>Abstract</b> .....                                                                     | 75 |
| <b>1 Introduction</b> .....                                                               | 76 |
| <b>2 Material and Methods</b> .....                                                       | 77 |
| <b>2.1 Sample preparation</b> .....                                                       | 77 |
| <b>2.2 NIR Spectroscopy</b> ..                                                            | 78 |
| <b>2.3 NIR hyperspectral imaging (NIR-HIS)</b> .....                                      | 78 |
| <b>2.4 RGB-Imaging (RGB-I)</b> .....                                                      | 79 |
| <b>2.4.1 Image analysis and feature extraction</b> .....                                  | 79 |
| <b>2.5 Multivariate analyses</b> .....                                                    | 79 |
| <b>2.5.1 Selection of most relevant wavelengths</b> .....                                 | 80 |
| <b>2.5.2 Adulteration map</b> .....                                                       | 80 |
| <b>3 Results and Discussion</b> .....                                                     | 81 |
| <b>3.1 Spectral analyses</b> .....                                                        | 81 |
| <b>3.2 Classification of ground meat</b> .....                                            | 81 |
| <b>3.3 Prediction of adulteration in ground chicken samples</b> .....                     | 85 |
| <b>3.4 Prediction of adulteration in chicken samples using selected wavelengths</b> ..... | 87 |
| <b>3.5 Predition map</b> .....                                                            | 89 |
| <b>4 Conclusion</b> .....                                                                 | 90 |
| <b>Acknowledgment</b> .....                                                               | 90 |
| <b>5 References</b> .....                                                                 | 90 |
| <b>CAPÍTULO 5</b> .....                                                                   | 95 |
| <b>DISCUSSÃO GERAL</b> .....                                                              | 95 |
| 5. Discussão Geral .....                                                                  | 97 |
| <b>CAPÍTULO 6</b> .....                                                                   | 98 |
| <b>CONCLUSÃO GERAL</b> .....                                                              | 98 |

|    |                                                        |     |
|----|--------------------------------------------------------|-----|
| 6. | Conclusão Geral .....                                  | 99  |
|    | <b>CAPÍTULO 7</b> .....                                | 99  |
|    | <b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....                | 99  |
|    | <b>ANEXOS</b> .....                                    | 117 |
| A. | ANEXO 1 - MEMÓRIA DO PERÍODO DE DOUTORADO .....        | 117 |
| B. | ANEXO 2 COMPROVANTE DO ARTIGO PUBLICADO.....           | 119 |
| C. | ANEXO 3 APRESENTAÇÃO DA DISTRIBUIÇÃO DAS AMOSTRAS..... | 120 |

# **CAPÍTULO 1**

## **Introdução geral, objetivos e estrutura da tese**

## 1. INTRODUÇÃO

Atualmente uma tendência global em alimentos é a exigência cada vez mais rigorosa por parte dos consumidores em relação à qualidade, segurança, legislação ambiental, ética, recursos de produção sustentável e ao custo dos produtos alimentares que adquirem. Essa tendência deve-se ao aumento do conhecimento científico sobre o impacto da alimentação na saúde humana, além da sensibilização dos consumidores em relação aos produtos alimentares, para garantir nutrição adequada, prevenir futuras doenças e melhorar as funções fisiológicas (GRANATO et al., 2010).

Produtos cárneos de diferentes espécies formam parte da dieta como fonte de energia, micronutrientes, aminoácidos essenciais e proteínas de alto valor biológico, sendo importantes na construção e manutenção dos tecidos, formação de hormônios, entre outros aspectos. Carnes de diferentes espécies apresentam características particulares: a carne suína é rica em lipídios, colesterol, ácidos graxos insaturados e saturados, vitamina do complexo B e diversos minerais (MARÇAL et al., 2016; SARCINELLI; VENTURINI; SILVA, 2007); a carne bovina contém elevada quantidade de proteína e gordura saturada (TROY; TIWARI; JOO, 2016); carne de frango, considerada carne branca, apresenta grande quantidade de aminoácidos essenciais e mais ácidos graxos poliinsaturados que as carnes vermelhas, e é aceita por todas as culturas e religiões do mundo (BERZAGHI et al., 2005; KONIECZKA; CZAUDERNA; SMULIKOWSKA, 2017; RAHBARI et al., 2018). Portanto, por conter estas proteínas, apresenta um valor biológico que influencia seu valor comercial, nutricional, qualidade sensorial, entre outros atributos (CHANAMAI; MCCLEMENTS, 1999; SAMS, 2001; VENTURI; SARCENELLI; SILVA, 2007; DALLA COSTA et al., 2016)

Garantir ao consumidor um produto de qualidade é imprescindível, além de ser necessário atender às demandas da indústria de alimentos e instituições reguladoras e fiscalizadoras na detecção imediata dos parâmetros de qualidade e autenticidade dos produtos derivados da carne. Assim, é necessário o uso de técnicas analíticas capazes de avaliar a sua composição e, no caso de carne crua, sua identificação e autenticidade. Os métodos analíticos tradicionais, no entanto, são de uso limitado, por serem destrutivos, demorados, requererem um longo tempo de preparação da amostra, além de estarem associados às inconsistências e falta de precisão (ELMASRY et al., 2012; HU et al., 2016).

Esses métodos não são práticos para a necessidades da indústria de análises rápidas e detecção de anormalidade em estágios iniciais do processamento, no que diz respeito aos

parâmetros de qualidade (ARIANA; LU; GUYER, 2006; BARBIN et al., 2015). Além disso, estes métodos não são práticos para determinar a adulteração de carnes por diferentes espécies ou por diferentes partes do animal da mesma espécie, acarretando prejuízo à confiança depositada na indústria, prejudicando a economia e até ofensa aos princípios de grupos religiosos (BARAKAT; EL-GARHY; MOUSTAFA, 2014; MANDLI et al., 2018; CHENG et al., 2016)

Em contrapartida, métodos rápidos, não destrutivos e não invasivos têm sido estudados como possíveis alternativas para a avaliação da qualidade de alimentos (BALAGE et al., 2015; DE MARCHI, 2013). Tais métodos devem ser simples, econômicos e capazes de fornecer resultados quantitativos (ALAMPRESE; FONGARO; CASIRAGHI, 2016; IQBAL; SUN; ALLEN, 2013). Entre esses métodos, as técnicas espectroscópicas têm sido estudadas pelas vantagens que oferecem na avaliação da qualidade, identidade e caracterização das mais diversas matrizes biológicas, devido à sua rapidez, precisão, confiabilidade, além de não utilizarem reagentes.

A espectroscopia no infravermelho próximo (NIR) pode ser utilizada na análise de vários atributos das amostras, para controle de processo e qualidade de produtos na indústria, no processamento contínuo de alimentos (ALEXANDRAKIS; DOWNEY; SCANNELL, 2012; LIU et al., 2012; WU et al., 2012), discriminação de carne (PRIETO et al., 2015) diferenciação entre frango fresco e congelado/descongelado (GRUNERT et al., 2016), identificação e quantificação de carne de peru (ALAMPRESE; FONGARO; CASIRAGHI, 2016), adulteração de carne (RADY; ADEDEJI, 2018), classificação rápida de filés de peito de frango intactos (JIANG et al., 2018; YANG et al., 2018), classificação de cortes de frango (NOLASCO PEREZ et al., 2018), e classificação de carcaças bovina em função do pH (REIS; ROSENVOLD, 2014). Todavia, a técnica espectroscópica convencional não é capaz de fornecer informações sobre a distribuição da composição, pois o equipamento incide sobre uma parte relativamente pequena da amostra que está sendo analisada, produzindo valores médios de composição. Há alguns casos onde é necessário visualizar a distribuição espacial dos parâmetros de qualidade (KAMRUZZAMAN et al., 2012a).

Técnicas de imagem foram desenvolvidas e vêm sendo utilizadas como um complemento aos métodos de espectroscopia. Essas técnicas surgiram como um instrumento de inspeção de qualidade, detecção e classificação de produtos agrícolas com mínima intervenção humana (KUMAR; MITTAL, 2010; PALLOTTINO et al., 2010). As imagens digitais fornecem

informações para a área de amostra completa ao invés de uma área reduzida (TRINDERUP et al., 2015), sendo usadas para discriminar carne bovina e carne de porco (ARSALANE et al., 2017), predição dos atributos da cor da carne do porco e da qualidade do lombo de porco (SUN et al., 2016, 2018), predição e identificação rápida do frescor da carne bovina (ARSALANE et al., 2018). Porém, esta técnica proporciona somente dados espaciais e não dados espectrais. Desse modo, a vantagem da combinação das técnicas de imagem e espectroscopia, dando origem assim ao sistema de imagem hiperespectral do infravermelho próximo (NIR-HSI), pode proporcionar a determinação simultânea de características físicas e químicas de uma amostra (KAMRUZZAMAN et al., 2012b; XIONG et al., 2015)

Os dados obtidos por técnicas de espectroscopia oferecem uma imensa quantidade de informação, sendo necessário utilizar métodos estatísticos, como a análise multivariada, capazes de extrair informações significativas de forma eficiente. Análises qualitativas como análises de componentes principais (PCA), análise dos mínimos quadrados parciais discriminantes (PLS-DA) e análises quantitativas como regressão linear múltipla (MLR), regressão pelo método dos quadrados mínimos parciais (PLS) e resolução de curvas multivariadas (MCR), são técnicas de análise multivariadas frequentemente utilizadas para investigar a correlação entre os dados espectrais de amostras testadas e quantidades reais ou concentrações de atributos de qualidade obtidos a partir das medições laboratoriais normais.

Quando associada à análise multivariada, a técnica de imagem hiperespectral provou ser uma ferramenta poderosa para análise de microrganismos e qualidade de peixe (CHENG; SUN, 2015a; CHENG et al., 2015), determinação de contagem total viável (TVC) (FENG; SUN, 2013), monitoramento de contaminação de bactérias em frangos (YE; IINO; ZHANG, 2016), predição de atributos de qualidades da carne (WU et al., 2012), composição química e adulteração de carne de cordeiro (KAMRUZZAMAN et al., 2013), adulteração da carne bovina (KAMRUZZAMAN; MAKINO; OSHITA, 2016), classificação de carne suína (BARBIN; ELMASRY; SUN; ALLEN, 2012) e avaliação visual de salame (ROMANO; MASI; CAVELLA, 2018). O aprendizado de máquina (ML) é outra das ferramentas utilizadas para tratamento de dados espectrais, através do reconhecimento automático de padrões de um banco de dados conhecidos para a tomada de decisões e previsões (LIU; YANG; DENG, 2015; CHEMURA; MUTANGA; DUBE, 2017).

De maneira geral, a indústria de carnes e as instituições reguladoras, bem como consumidor, podem se beneficiar destas tecnologias, para análises de autenticação e detecção de mistura de carnes, de acordo com sua necessidade.

## 2. OBJETIVOS

### 2.1. Objetivo geral

Caracterizar e identificar a carne de frango por métodos não destrutivos, comparando as técnicas de espectroscópica no infravermelho próximo (espectrômetro *NIR* portátil), imagem hiperespectral (*NIR-HSI*), e imagem digital *RGB* (*RGB-I*).

### 2.2. Objetivos específicos

- Avaliar o equipamento portátil de espectroscopia no infravermelho próximo para detecção rápida de amostras de frango de diferentes partes (peito, coxa e sobrecoxa);
- Comparar e investigar o potencial das técnicas de espectroscopia no infravermelho (espectrômetro *NIR* portátil, imagens hiperespectrais) e imagens *RGB* para identificar amostras de carnes de diferentes espécies, bem como determinar a quantidade de misturas de amostras moídas de carne bovina e suína em frango;
- Comparar os métodos de seleção de comprimentos de onda e as variáveis mais significativas associadas aos atributos qualitativos e quantitativos das amostras e testar a precisão dos modelos utilizando comprimentos de onda selecionados nos modelos de calibração e predição;

## 3. ESTRUTURA DA TESE

A tese está dividida em 7 capítulos juntamente com o apêndice e anexos. **Capítulo 1** – “Introdução, Objetivo Geral e Específicos e Estrutura da Tese” contém uma introdução, os objetivos e as etapas envolvidas no desenvolvimento do projeto. Os esquemas mostrados nas Figuras 1 e 2, destacam o fluxograma da parte experimental. As partes experimentais foram realizadas no Laboratório de Inovação em Alimentos (LINA), onde foram feitas as análises de espectroscopia no infravermelho com equipamento portátil, imagem *RGB* e análises de

umidade e pH; Laboratório de Engenharia de Processos (LEP) onde foram feitas as análises de cor e cinzas; Laboratório de Carnes e Derivados (LCD) do Departamento de Tecnologia de Alimentos onde foram feitas análises de proteínas e lipídios; e Laboratório do Grupo de Instrumentação e Automação em Química Analítica (GIA) do Instituto de Química (IQ) onde foram feitas as análises de imagem hiperespectral, todos na Universidade de Campinas (UNICAMP).

**Capítulo 2** – “Revisão de literatura”. Apresenta uma revisão sobre a matéria prima, demanda de produção, composição química e controle de qualidade da carne de aves e as técnicas de espectroscopia no infravermelho próximo utilizando equipamento portátil, imagem RGB e imagem hiperespectral e tratamentos dos dados como a quimiometria e aprendizado de máquina.

**Capítulo 3** – Artigo intitulado “*Classification of Chicken Parts Using a Portable Near-Infrared (NIR) Spectrophotometer and Machine Learning*”, publicado na revista *Applied Spectroscopy*

**Capítulo 4** – Artigo intitulado “*Comparison of rapid techniques for classification of ground meat*”, submetido a revista *Biosystems Engineering*

**Capítulo 5** – Apresenta a discussão geral dos resultados.

**Capítulo 6** – Apresenta as conclusões gerais do projeto.

**Capítulo 7** – Anexos

**Anexo 1** – Apresenta a memória do autor, onde são listados as disciplinas cursadas e estágios de docência realizados, trabalhos científicos publicados em periódicos e eventos internacionais decorrentes do projeto.

**Anexo 2** - Comprovante de publicação do artigo

**Anexo 3** - Apresentação da distribuição das amostra




Figura 1. Diagrama de fluxo da parte experimental da tese




Figura 2. Diagrama de fluxo do processamento.

## Referências

- ALAMPRESE, C.; FONGARO, L.; CASIRAGHI, E. Effect of fresh pork meat conditioning on quality characteristics of salami. **Meat Science**, v. 119, p. 193-198, 1 set. 2016.
- ALEXANDRAKIS, D.; DOWNEY, G.; SCANNELL, A. G. M. Rapid Non-destructive Detection of Spoilage of Intact Chicken Breast Muscle Using Near-infrared and Fourier Transform Mid-infrared Spectroscopy and Multivariate Statistics. **Food and Bioprocess Technology**, v. 5, n. 1, p. 338-347, 9 jan. 2012.
- ARIANA, D. P.; LU, R.; GUYER, D. E. Near-infrared hyperspectral reflectance imaging for detection of bruises on pickling cucumbers. **Computers and Electronics in Agriculture**, v. 53, n. 1, p. 60-70, 1 ago. 2006.
- ARSALANE, A.; BARBRI, N. E.; RHOFIR, K.; TABYAOUI, A.; & KLILOU, A. Beef and horse meat discrimination and storage time classification using a portable device based on DSP and PCA method. **International Journal of Intelligent Enterprise**, v. 4, n. 1-2, p. 58-75, 2017.
- ARSALANE, A.; EL BARBRI, N.; TABYAOUI, A.; KLILOU, A.; RHOFIR, K.; HALIMI, A. 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, n. July, p. 385-392, 2018.
- BALAGE, J. M.; E SILVA, S. D. L.; GOMIDE, C. A., DE NADAI BONIN, M.; & FIGUEIRA, A. C. Predicting pork quality using Vis/NIR spectroscopy. **Meat science**, v. 108, p. 37-43, out. 2015.
- BARBIN, D.; ELMASRY, G.; SUN, D. W.; ALLEN, P. Near-infrared hyperspectral imaging for grading and classification of pork. **Meat Science**, v. 90, n. 1, p. 259-268, 1 jan. 2012.
- BARBIN, D. F.; KAMINISHIKAWAHARA, C. M.; SOARES, A. L.; MIZUBUTI, I. Y.; GRESPAN, M.; SHIMOKOMAKI, M.; HIROOKA, E. Y. Prediction of chicken quality attributes by near infrared spectroscopy. **Food Chemistry**, v. 168, p. 554-560, 1 fev. 2015.
- BARAKAT, H.; EL-GARHY, H. A. S.; MOUSTAFA, M. M. A. Detection of pork adulteration in processed meat by species-specific PCR-QIAxcel procedure based on D-loop and cytb genes. **Applied Microbiology and Biotechnology**, v. 98, n. 23, p. 9805-9816, 17 dez. 2014.
- BERZAGHI, P.; DALLE ZOTTE, A.; JANSSEN, L. M.; ANDRIGHETTO, I. Near-infrared reflectance spectroscopy as a method to predict chemical composition of breast meat and discriminate between different n-3 feeding sources. **Poultry Science**, v. 84, n. 1, p. 128-136, 2005.
- CHANAMAI, R.; MCCLEMENTS, D. J. Ultrasonic determination of chicken composition. **Journal of Agricultural and Food Chemistry**, v. 47, n. 11, 1999.
- CHEMURA, A.; MUTANGA, O.; DUBE, T. Remote sensing leaf water stress in coffee (*Coffea arabica*) using secondary effects of water absorption and random forests. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 100, p. 317-324, 1 ago. 2017.

CHENG, J.-H.; SUN, D.-W. Rapid and non-invasive detection of fish microbial spoilage by visible and near infrared hyperspectral imaging and multivariate analysis. **LWT - Food Science and Technology**, v. 62, n. 2, p. 1060-1068, 1 jul. 2015a.

CHENG, J. H.; SUN, D. W.; PU, H. B.; CHEN, X.; LIU, Y.; ZHANG, H.; LI, J. L. Integration of classifiers analysis and hyperspectral imaging for rapid discrimination of fresh from cold-stored and frozen-thawed fish fillets. **Journal of Food Engineering**, v. 161, p. 33-39, 1 set. 2015.

DALLA COSTA, F. A.; DE CASTRO TAVERNARI, F.; DALLA COSTA, O. A.; DE CASTRO, F. F.; REMUS, A. Enriquecimento com ácidos graxos da série ômega 3 em carne de aves e ovos. **Pubvet**, v. 11, p. 103-206. 2016.

DE MARCHI, M. On-line prediction of beef quality traits using near infrared spectroscopy. **Meat Science**, v. 94, n. 4, p. 455-460, 2013.

ELMASRY, G.; BARBIN, D. F.; SUN, D. W.; ALLEN, P. Meat Quality Evaluation by Hyperspectral Imaging Technique: An Overview. **Critical Reviews in Food Science and Nutrition**, v. 52, n. 8, p. 689-711, 2012.

FENG, Y.-Z.; SUN, D.-W. Determination of total viable count (TVC) in chicken breast fillets by near-infrared hyperspectral imaging and spectroscopic transforms. **Talanta**, v. 105, p. 244-249, 15 fev. 2013.

GRANATO D.; BRANCO G. F.; NAZZARO F.; CRUZ A. G.; AND F. J. A. . Functional Foodsand NondairyProbiotic FoodDevelopment:Trends,Concepts, and Products. Comprehensive Reviews In **Food Science and Food Safety**, v. 9, p. 292-302, 2010.

GRUNERT, T.; STEPHAN, R.; EHLING-SCHULZ, M.; JOHLER, S. Fourier Transform Infrared Spectroscopy enables rapid differentiation of fresh and frozen/thawed chicken. **Food Control**, v. 60, p. 361-364, fev. 2016.

HU, M. H.; DONG, Q. L.; LIU, B. L.; OPARA, U. L. Prediction of mechanical properties of blueberry using hyperspectral interactance imaging. **Postharvest Biology and Technology**, v. 115, p. 122-131, 1 maio 2016.

HUANG, H.; LIU, L.; NGADI, M. O. Prediction of pork fat attributes using NIR Images of frozen and thawed pork. **Meat Science**, v. 119, 2016.

IQBAL, A.; SUN, D.-W.; ALLEN, P. Prediction of moisture, color and pH in cooked, pre-sliced turkey hams by NIR hyperspectral imaging system. **Journal of Food Engineering**, v. 117, n. 1, p. 42-51, jul. 2013.

JIANG, H.; YOON, S. C.; ZHUANG, H.; WANG, W.; LAWRENCE, K. C.; YANG, Y. Tenderness classification of fresh broiler breast fillets using visible and near-infrared hyperspectral imaging. **Meat Science**, v. 139, p. 82-90, 1 maio 2018.

KAMRUZZAMAN, M.; ELMASRY, G.; SUN, D. W.; ; ALLEN, P. Prediction of some quality attributes of lamb meat using near-infrared hyperspectral imaging and multivariate analysis. **Analytica Chimica Acta**, v. 714,p 57-67, 2012a.

KAMRUZZAMAN, M.; BARBIN, D.; ELMASRY, G.; SUN, D. W.; ALLEN, P. Potential of hyperspectral imaging and pattern recognition for categorization and authentication of red meat. **Innovative Food Science & Emerging Technologies**, v. 16, p. 316-325, out. 2012b

KAMRUZZAMAN, M. et al. Fast detection and visualization of minced lamb meat adulteration using NIR hyperspectral imaging and multivariate image analysis. **Talanta**, v. 103, 2013.

KAMRUZZAMAN, M.; MAKINO, Y.; OSHITA, S. Rapid and non-destructive detection of chicken adulteration in minced beef using visible near-infrared hyperspectral imaging and machine learning. **Journal of Food Engineering**, v. 170, p. 8-15, 1 fev. 2016.

KONIECZKA, P.; CZAUDERNA, M.; SMULIKOWSKA, S. The enrichment of chicken meat with omega-3 fatty acids by dietary fish oil or its mixture with rapeseed or flaxseed—Effect of feeding duration: Dietary fish oil, flaxseed, and rapeseed and n-3 enriched broiler meat. **Animal Feed Science and Technology**, v. 223, p. 42–52, 1 jan. 2017.

KUMAR, S.; MITTAL, G. S. Rapid detection of microorganisms using image processing parameters and neural network. **Food and Bioprocess Technology**, v. 3, n. 5, p. 741-751, 2010.

LIU, C.; YANG, S. X.; DENG, L. Determination of internal qualities of Newhall navel oranges based on NIR spectroscopy using machine learning. **Journal of Food Engineering**, v. 161, p. 16-23, 1 set. 2015.

LIU, Y.; GAO, R.; HAO, Y.; SUN, X.; OUYANG, A. Improvement of Near-Infrared Spectral Calibration Models for Brix Prediction in “Gannan” Navel Oranges by a Portable Near-Infrared Device. **Food and Bioprocess Technology**, v. 5, n. 3, p. 1106-1112, 15 abr. 2012.

MANDLI, J.; FATIMI, I. E.; SEDDAOUI, N.; AMINE, A. Enzyme immunoassay (ELISA/immunosensor) for a sensitive detection of pork adulteration in meat. **Food Chemistry**, v. 255, p. 380–389, 30 jul. 2018.

MARÇAL, D. A.; DE ABREU, R. C.; CHEUNG, T. L.; KIEFER, C. Consumo da carne suína no Brasil: Aspectos simbólicos como determinantes dos comportamentos. **Revista em Agronegócio e Meio Ambiente**, v. 9, n. 4, p. 989–1005, 2016.

NOLASCO PEREZ, I. M.; BADARÓ, A. T.; BARBON JR, S.; BARBON, A. P. A.; POLLONIO, M. A. R.; BARBIN, D. F. Classification of Chicken Parts Using a Portable Near-Infrared (NIR) Spectrophotometer and Machine Learning. **Applied Spectroscopy**, v. 0, n. 0, p. 370281878887, 2018.

PALLOTTINO, F.; MENESATTI, P.; COSTA, C.; PAGLIA, G.; DE SALVADOR, F. R.; LOLLETTI, D. Image analysis techniques for automated hazelnut peeling determination. **Food and Bioprocess Technology**, v. 3, n. 1, p. 155-159, 2010.

PRIETO, N.; AALHUS, J. L.; LOPEZ-CAMPOS, O.; ZIJLSTRA, R. T.; JUÁREZ, M. Discrimination of beef dark cutters and enhanced quality pork using visible and near infrared spectroscopy. **Meat Science**, v. 101, p. 144-145, mar. 2015.

RADY, A.; ADEDEJI, A. Assessing different processed meats for adulterants using visible-near-infrared spectroscopy. **Meat Science**, v. 136, p. 59-67, 1 fev. 2018.

RAHBARI, M., HAMDAMI, N., MIRZAEI, H., JAFARI, S. M., KASHANINEJAD, M., & KHOMEIRI, M. Effects of high voltage electric field thawing on the characteristics of chicken breast protein. **Journal of Food Engineering**, v. 216, p. 98–106, 1 jan. 2018.

REIS, M. M.; ROSENVOLD, K. Early on-line classification of beef carcasses based on ultimate pH by near infrared spectroscopy. **Meat Science**, v. 96, n. 2, p. 862–869, 1 fev. 2014.

ROMANO, A.; MASI, P.; CAVELLA, S. Visual evaluation of sliced Italian salami by image analysis. **Food Science and Nutrition**, v. 6, n. 1, p. 153-159, 2018.

SARCINELLI, M. F.; VENTURINI, K. S.; SILVA, L. C. DA. Características da Carne Suína. **Revista Brasileira de Zootecnia**, v. 1, n. 1, p. 1–7, 2007.

SUN, X.; YOUNG, J.; LIU, J. H.; BACHMEIER, L.; SOMERS, R. M.; CHEN, K. J.; NEWMAN, D. Prediction of pork color attributes using computer vision system. **Meat Science**, v. 113, p. 62-64, 1 mar. 2016.

SUN, X.; YOUNG, J.; LIU, J. H.; NEWMAN, D. Prediction of pork loin quality using online computer vision system and artificial intelligence model. **Meat Science**, v. 140, p. 72-77, 1 jun. 2018.

TRINDERUP, C. H.; DAHL, A.; JENSEN, K.; CARSTENSEN, J. M.; CONRADSEN, K. Comparison of a multispectral vision system and a colorimeter for the assessment of meat color. **Meat science**, v. 102, p. 1-7, April 2015.

TROY, D. J.; TIWARI, B. K.; JOO, S. T. Health Implications of Beef Intramuscular Fat Consumption. **Korean Journal for Food Science of Animal Resources**, v. 36, n. 5, p. 577–582, 2016.

XIONG, Z.; XIE, A.; SUN, D. W.; ZENG, X. A.; LIU, D. Applications of Hyperspectral Imaging in Chicken Meat Safety and Quality Detection and Evaluation: A Review. **Critical Reviews in Food Science and Nutrition**, v. 55, n. 9, p. 1287–1301, 2015.

VENTURINI, K. S.; SARCINELLI, M. F.; SILVA, L. D. Características da carne de frango. **Boletim Técnico-Pie-Ufes**, 1307. 2007.

WU, J.; PENG, Y.; LI, Y.; WANG, W.; CHEN, J.; DHAKAL, S. Prediction of beef quality attributes using VIS/NIR hyperspectral scattering imaging technique. **Journal of Food Engineering**, v. 109, n. 2, p. 267-273, mar. 2012.

YANG, Y.; ZHUANG, H.; YOON, S. C.; WANG, W.; JIANG, H.; JIA, B. Rapid classification of intact chicken breast fillets by predicting principal component score of quality traits with visible/near-Infrared spectroscopy. **Food Chemistry**, v. 244, p. 184-189, 1 abr. 2018.

YE, X.; IINO, K.; ZHANG, S. Monitoring of bacterial contamination on chicken meat surface using a novel narrowband spectral index derived from hyperspectral imagery data. **Meat science**, v. 122, p. 25-31, dez. 2016.

# **CAPÍTULO 2**

## **Revisão da literatura**

## 2. REVISÃO DA LITERATURA

### 2.1. Materia-prima

O consumo de carne de frango vem aumentando cada vez mais devido a diversos fatores como baixo preço, propriedades sensoriais, baixa quantidade de gordura na dieta, quando ocorre a remoção da pele, entre outros. A indústria tem desenvolvido cada vez mais novos produtos processados para atender às necessidades dos consumidores e aproveitar partes da carne de menor valor. A carne de aves é mais homogênea em sua composição, textura e cor, e é mais fácil de formular produtos de forma consistente quando comparada com a carne bovina (SAMS, 2001; VENTURI; SARCENELLI; SILVA, 2007; DALLA COSTA, 2016).

A carne de frango, por exemplo, é um produto de grande importância na dieta humana, uma vez que tem um conteúdo energético moderado, proteínas de ótima qualidade nutricional, lipídios, vitaminas e minerais. Sua qualidade pode ser influenciada por diversos fatores como linhagem, genótipo, sexo, peso de abate, tipo de alimentação, idade, sistema de criação e estresse pré-abate (XIONG et al., 2015b).

Tabela 1 - Consumo de frango no Brasil e no mundo (1000 TM)

|        | Carnes | 2015    | 2016    | 2017    | 2018    | 2019 (out) |
|--------|--------|---------|---------|---------|---------|------------|
| Brasil | Frango | 9.710   | 9.637   | 9.768   | 9.866   | 10.026     |
|        | Bovina | 7.781   | 7.659   | 8.227   | 8.530   | 8.705      |
|        | Suina  | 2.893   | 2.870   | 2.941   | 2.992   | 3.042      |
| Mundo  | Frango | 89.587  | 90.740  | 92.034  | 93.787  | 95.974     |
|        | Bovina | 57.812  | 58.756  | 59.674  | 60.724  | 61.734     |
|        | Suina  | 109.941 | 109.818 | 110.584 | 112,433 | 114.211    |

FONTE: USDA, 2019.

O Brasil é considerado o maior consumidor interno (Tabela 1) e um dos maiores exportadores de carne de frango (USDA, 2019). Segundo estatísticas (Tabela 2), os Estados Unidos, Brasil e China mantêm sua liderança como maiores produtores de carne de frango, contando com mais de 50 milhões de toneladas por ano de produção, onde cada país produziu no ano 2018, respectivamente, 19.350, 13.550 e 11.700 toneladas de carne de frango (USDA, 2019). A produção anual da União Europeia em 2018 foi 12.315 milhões de toneladas. O consumo de carne de frango superou o de carne bovina, em nível mundial, Tabela 2.

Tabela 2 - Produção de carne de frango (1000 TM)

| País           | 2015   | 2016   | 2017   | 2018   | 2019(out) |
|----------------|--------|--------|--------|--------|-----------|
| Estados Unidos | 18.208 | 18.510 | 18.938 | 19.350 | 19.709    |
| China          | 13.561 | 12.448 | 11.600 | 11.700 | 12.000    |
| Brasil         | 13.547 | 13.523 | 13.612 | 13.550 | 13.800    |
| União Europeia | 10.890 | 11.560 | 12.060 | 12.315 | 12.470    |
| Total          | 56.206 | 56.041 | 56.210 | 56.915 | 57.979    |

FONTE: USDA, 2019.

### 2.1.1. Composição química da carne de aves

A carne de aves é fonte de proteína de alta qualidade, apresentando baixos níveis de colágenos, lipídios insaturados (encontrados na maior parte da pele e facilmente removidos, uma vez que a pele corresponde a 25-30% do teor calórico), sendo considerada uma carne magra quando comparada com carne vermelha (Tabela 3). Além disso, contém vitaminas do grupo B (tiamina, vitamina B6 e ácido pantotênico) e minerais (ferro, zinco e cobre) (ALEXANDRAKIS; DOWNEY; SCANNELL, 2012; BRANDELLI; SALA; KALIL, 2015; RAHBARI et al., 2018).

Tabela 3 - Composição da carne de frango.

| Espécie | Carne  | Pele | Água* | Proteína* | Lipídios* | Cinzas* | Ferro* | Calorias* |
|---------|--------|------|-------|-----------|-----------|---------|--------|-----------|
| Frango  | Branca | +    | 68.6  | 20.3      | 11.1      | 0.86    | 0.8    | 186       |
|         | Branca | -    | 74.9  | 23.2      | 1.6       | 0.98    | 0.7    | 114       |
|         | Escura | +    | 65.4  | 16.7      | 18.3      | 0.76    | 1.0    | 237       |
|         | Escura | -    | 75.9  | 20.1      | 4.3       | 0.94    | 1.0    | 125       |

\*Valores expressos em 100 gramas de porção de carne, com/sem pele.

Branca refere-se ao peito

Escura refere-se as extremidades inferiores (sobrecosta e coxa)

FONTE: BARBUT, 2002.

A Tabela 4 apresenta, ainda, outros dados significativos em carne de aves, que são os tipos de gordura presentes. Pode-se observar que a carne de frango apresenta menor teor de gordura saturada e maior teor de gordura insaturada que a carne suína e a bovina, trazendo benefícios para a saúde humana diminuindo a possibilidade hipercolesterolemia e doenças

cardiovasculares (BARBUT, 2002; TROY; TIWARI; JOO, 2016). Além disso apresenta maior quantidade de gorduras insaturadas dentro das quais temos os ácidos graxos essenciais (ácidos linoleico e alfa-linolênico). Armazenamento a baixas temperaturas e por curtos períodos é necessário para diminuir problemas com a estabilidade oxidativa de carnes de frango (MOREIRA, 2015; PINO, 2005).

Tabela 4 - Porcentagem do tipo de gordura.

| Tipo de gordura | Frango | Bovino | Suíno |
|-----------------|--------|--------|-------|
| % Saturada      | 33     | 54     | 42    |
| % Insaturada    | 67     | 46     | 58    |

FONTE: BARBUT, 2002.

### 2.1.2. Abate de frango e desossa da carcaça

A carne comercialmente comestível é aquela que elimina componentes não desejados como o sangue, vísceras, patas, cabeça, etc. Em cada etapa do processo deve-se ter estrito controle evitando lesões, ossos quebrados, partes ausentes da carcaça para evitar perdas. Carcaça é o produto obtido depois do pre-abate sem miúdos (moela, fígado, coração) e outras partes (pés, cabeça e pescoço). O frango é comercializado no Brasil inteiro com osso e com pele, ou os cortes de frango, sendo o peito considerado o mais nobre ou importante do frango, comercializado como filé, além de outros cortes importantes como coxa e sobrecoxa, comercializadas separadamente. (VEZANNI, 1986; SARCENELLI; VENTURINI; DA SILVA, 2007). Para obter a carne comercialmente comestível se realizam os seguintes procedimentos de pre-abate:

- 1) Recebimento: frango vivo em caixas
- 2) Pendura das aves: realizada pelas patas evitando qualquer lesão.
- 3) Insensibilização: consiste na submersão numa solução salina com corrente elétrica, cuja voltagem pode variar conforme o tamanho, idade e tipo de aves. Esta etapa só deve deixar a ave atordoada, após a sangria. A insensibilização facilita a operação de sangria, deixando o animal imóvel, e evitando contusões principalmente, nas asas.
- 4) Sangria: pequeno corte da secção dos vasos do pescoço sem a separação da cabeça, em túnel de gotejamento,
- 5) Escaldagem: as aves são submergidas não mais de 2,5 minutos a 52°C com agitação para afrouxamento das penas,

6) Depenagem: retirada das penas através de tambores rotativos com dedos de borracha para evitar lesões na carcaça

7) Evisceração: corte do animal e retirada das vísceras

8) Pre-resfriamento e resfriamento: realizada em duas etapas, com um pré-resfriamento seguido do resfriamento definitivo. Dois equipamentos são necessários para esta etapa (pré-chiller seguido do chiller), ocorrendo no primeiro o resfriamento à temperatura de 25°C das carcaças, limpeza e reidratação da carcaça, imediatamente após as etapas de evisceração e lavagem, realizadas por sistema de imersão em água gelada e/ou água e gelo ou passagem por túnel de resfriamento. No segundo resfriamento finaliza-se o processo de resfriamento reduzindo a temperatura até 4°C com a finalidade de eliminar o calor “post mortem” e evitar a proliferação de micro-organismos.

9) Gotejamento: as carcaças são penduradas pelo pescoço ou canela com a finalidade de remover o excesso de água, por aproximadamente 3 minutos (quantidade final de água da carcaça deve ser de 8% de seu peso para o mercado nacional e 4,5% para o mercado internacional),

10) Inspeção: verificação da presença de hematomas,

11) Desossa: carcaça é separada em partes, ou cortes,

A seguir, acontecem as etapas pós-abate:

1) Corte das carcaças, se realizam diferentes tipos de cortes de acordo com exigência do cliente, a ordem dos cortes depende de cada empresa. Nesta etapa a temperatura não deve sobre passar os 12°C para garantir a qualidade;

2) Embalagem;

3) Congelamento: as caixas são conduzidas ao túnel de congelamento onde são mantidas por 8 horas.

4) Estocagem: após o congelamento são colocados em “pallets” para cada produto e destinados a câmara de estocagem a -23° até o embarque. (DE OLIVEIRA, 2014; PINTO et al., 2015).

### **2.1.3. Tipos de fibra nos cortes de Frango**

Os cortes (músculos) do frango estão constituídas por diferentes tipos de fibra. Tipo I - contração lenta e oxidativa (SO (Slow Oxidative)) ; tipo IIA - contração rápida, oxidativa e glicolítica (FOG (Fast Oxidative Glycolytic)); e tipo IIB - contração rápida e glicolítica (FG (Fast Glycolytic)). As fibras do tipo I são pequenas, de cor vermelhas devido a mioglobina e

contém numerosas mitocôndrias. No tipo II são células musculares grandes com pequenas quantidades de mioglobina e mitocôndrias, sendo que as fibras no tipo IIA são resistentes à fadiga e as fibras no tipo IIB são facilmente fatigáveis, e acumulam ácido lático. Nos pectorais predominam as fibras FG e FOG e na coxa e sobre coxa predominam as fibras SO e FOG (MADEIRA et al., 2006).

#### **2.1.4. Classificação de carnes e técnicas de autenticidade de carne**

Alguns fatores afetam a qualidade e segurança da carne de frango durante o processamento; por ser perecíveis e vulneráveis a deterioração microbiológica, pode sofrer contaminação durante o processamento, bem como perda da qualidade e frescor durante o armazenamento (JIANG et al., 2018; WOLD et al., 2017; CHENG; NICOLAI; SUN, 2017). Além disso, alteração dos parâmetros de qualidade como cor (presença de hematomas), capacidade de retenção de água (em excesso), e o pH devem ser controladas durante o processo (BOWKER; HAWKINS; ZHUANG, 2014; ZHUANG; SAVAGE, 2012). Garantir a qualidade e procedência de amostras de carne moída é muito mais difícil devido a perda da estrutura morfológica. (KAMRUZZAMAN; MAKINO; OSHITA, 2016).

Métodos analíticos tradicionais tem sido utilizados para determinar a presença de elementos externos ao produto cárneo original. Entre esses diversos métodos temos a reação da cadeia de polimerase (PCR), DNA mitocondrial (SUNTRARACHUN; CHANHOM; SUMONTHA, 2018), ELISA (MANDLI et al., 2018) e determinação de proteínas marcadoras com LC-MS/MS (SONG; LEE; KIM, 2016), marcadores da mioglobina com cromatografia líquida (GIARETTA et al., 2013), tecnologias proteômicas com espectrometria de massa (SARAH et al., 2016), eletroforese (HERNÁNDEZ-CHÁVEZ et al., 2011). Estes métodos são capazes de autenticar a carne e verificar a presença de outro elementos em baixas concentrações com exatidão. No entanto esses métodos são destrutivos, requerem pessoal altamente treinado, e impedem utilização em tempo real no processo produtivo.

A indústria de carnes, por ser dinâmica, exige métodos mais rápidos e de menor custo que permitam sua adaptabilidade aos sistemas de produção *on-line*, como as técnicas espectroscópicas.

#### **2.2. Espectroscopia no infravermelho próximo (NIR)**

A tecnologia de espectroscopia no infravermelho próximo (NIR) envolve a luz que interage com o material sobre o qual ocorre a radiação eletromagnética. Essa tecnologia fornece a absorção de luz em cada comprimento de onda, que é expresso em nanômetros (nm). A parte

do espectro visível ao olho humano varia entre 400 e 750 nm, enquanto o espectro de infravermelho se estende de 750 nm a 1000000 nm. A região espectral no infravermelho é dividida em três sub-regiões, região do infravermelho próximo (*NIR*) varia entre 750 a 2500nm, região do infravermelho médio (*MIR*) estende-se de 2500 a 25000nm e infravermelho distante (*FIR*) varia de  $25 \times 10^3$  a  $100 \times 10^3$  (SOUZA, 2013; OSBORNE et al., 1993; SMITH, 2001, PASQUINI 2018).

Em geral, a absorção no infravermelho é restrita a espécies moleculares que possuem pequenas diferenças de energias entre os diferentes estados vibracionais (SANDORY, BUCHET; LACHENAL, 2007; NETO, 2005). As transições de vibração das moléculas são provocadas pela variação da energia quando existe uma incidência de radiação infravermelha e ocorre a absorbância, refletância e/ou transmitância.

A frequência de vibração molecular ( $\nu_m$ ) é calculada a partir da Equação 1 (SOUZA, 2013) depois de substituir a massa  $m_1$  e  $m_2$  de dois átomos.

$$\nu_m = \frac{1}{2\pi} \sqrt{\frac{k}{u}} = \frac{1}{2\pi} \sqrt{\frac{k(m_1+m_2)}{m_1 m_2}} \quad \text{Equação 1}$$

$k$  = constante da força de ligação em newtons por metro (N/m);

$u$  = masa reduzida de  $m_1$  e  $m_2$  conectados por uma mola (kg);

$\nu_m$  = frequência vibracional

Para expor o comportamento das partículas de dimensões atômicas é necessário descrever as equações de onda da mecânica quântica (Equação 2), considerando-se o conceito de oscilador harmônico.

$$E(v) = \left(n + \frac{1}{2}\right) \frac{h}{2\pi} \sqrt{\frac{k}{u}} \quad \text{Equação 2}$$

Transições dos níveis de energia vibracional podem ocorrer devido à absorção de radiação e energia onde ocorrem diferenças nos estados quânticos vibracionais, na variação do momento de dipolo. A partir das Equações 1 e 2, obtêm-se a Equação 3.

$$E(v) = \left(n + \frac{1}{2}\right) \frac{h}{2\pi} \nu_m \quad \text{Equação 3}$$

$E(v)$  = Energia vibracional;

$n$  = número quântico vibracional ( $6,63 \times 10^{-34}$  Joule-seg.);

$h$  = constante de Planck (PASQUINI, 2003; WILLIAMS & NORRIS, 2001).

Em temperatura ambiente, as moléculas estão, essencialmente, em seu nível de energia vibracional fundamental ( $n = 0$ ). A energia vibracional é função transitória da molécula do primeiro nível de energia,  $n = 0$ , para o primeiro estado excitado  $n = 1$ , tal como descrito nas Equações 4 e 5.

$$E_0 = \left(\frac{1}{2}\right) h m_v \quad \text{Equação 4}$$

$$E_1 = \left(\frac{3}{2}\right) h m_v \quad \text{Equação 5}$$

A frequência da radiação  $\nu$  que produzirá esta variação de energia é idêntica à frequência vibracional clássica, como apresentado na Equação 6.

$$\nu = \nu_m = \frac{1}{2\pi} \sqrt{\frac{k}{u}} \quad \text{Equação 6}$$

Para expressar a radiação em números de onda, rearranja-se a equação 6, obtendo a Equação 7.

$$\nu = \nu_m = \frac{1}{2\pi} \sqrt{\frac{k}{u}} = 5.3 \times 10^{-12} \sqrt{\frac{k}{u}} \quad \text{Equação 7}$$

$\nu$  = número de onda associada a radiação absorvida de absorção ( $\text{cm}^{-1}$ );

Esta equação pode ser usada para estimar o número de onda da banda de absorção fundamental ou absorção devido à transição entre o estado fundamental para o primeiro estado excitado de uma variedade de tipos de ligação (HSU, 1997).

### 2.2.1. Modos de medição

Existem três modos de obtenção do espectro NIR: transflectância, transmitância e reflectância.

#### 2.2.1.1. Transmitância

O princípio básico de espectroscopia de transmissão é que a luz passa através de uma amostra límpida ou transparente e são medidas em cubetas transparentes que variam de 1 a 50 mm. A transmitância vai de um caminho mais longo a um caminho mais curto à medida que o comprimento de onda passa dos *sobretons* de ordem superior para a região de combinação em torno de 220 nm. A energia é absorvida pelos componentes químicos e medida pela espectroscopia UV-VIS. A medida pode ser utilizada em filmes e líquidos, bem como medidas de reflectância difusa com amostras de elevada quantidade de água (PASQUINI, 2003).

### **2.2.1.2. Reflectância**

As medidas de reflectância são predominantemente utilizadas na região de espectroscopia *NIR* para a obtenção de espectros de materiais sólidos. As bandas de absorção são devido a bandas de combinação, isto é, estiramento C-H e bandas de combinação. Na espectroscopia de reflectância, a luz ilumina, interagindo com materiais e re-irradia energia difusa refletida de volta para o plano de iluminação. A luz re-irradiada é detectada em ângulo de 45 graus, a fim de reduzir reflectância especular.

### **2.2.1.3. Transmitância difusa**

Nomeada assim quando se refere como transreflectância. O processo nesta medição é uma combinação de reflectância e de transmissão.

A análise de alimentos tem encontrado utilidade nas técnicas de reflectância e transreflectância, apropriadas para a medição de alta umidade e produtos com alto teor de gordura, como carne, produtos lácteos, compotas, conservas, massas, entre outros (PASQUINI, 2003).

### **2.2.2. Equipamento**

O espectrômetro *NIR* foi desenvolvido inicialmente para utilização em bancadas de laboratório, e desde então evoluiu para equipamentos menores, permitindo a portabilidade para utilização em campo e instalações em linhas de processamento. Estes instrumentos podem ser oferecidos em vários modelos com características diferentes relacionadas principalmente a faixa espectral. Alguns não requerem fonte externa de radiação, oferecendo tecnologias modernas de troca de dados digitais sem fio, como o Bluetooth (PASQUINI, 2018).

### **2.2.3. Aplicações de espectroscopia no infravermelho próximo (*NIR*)**

Atualmente as aplicações da espectroscopia no infravermelho próximo são diversas e amplamente utilizadas para prever os parâmetros de qualidade da carne como período pós-abate (ALAMPRESE; FONGARO; CASIRAGHI, 2016; BALAGE et al., 2015; FONGARO; ALAMPRESE; CASIRAGHI, 2015), cor, umidade, pH, (ZHENG et al., 2016); conteúdo de lipídios (CHIESA et al., 2016; PULLANAGARI; YULE; AGNEW, 2015; ZHOU et al., 2012) e composição química (PRIETO et al., 2014; SU et al., 2014).

A tecnologia *NIR* tem sido aplicada devido às suas vantagens sobre os métodos tradicionais de avaliação da qualidade, tais como medições rápidas e frequentes, pouca ou nenhuma preparação da amostra necessária, aptidão para utilização em linha e determinação simultânea de diferentes atributos. Infelizmente, a técnica *NIR* apresenta algumas

desvantagens, como ser incapaz de fornecer a distribuição de constituintes da amostra, uma vez que mede apenas a quantidade total de luz refletida ou transmitida de uma área específica da amostra (medição no ponto onde o sensor está localizado) e não contém informações ou é limitada sobre a distribuição espacial na amostra. Assim, esta medida pontual pode não ser representativa de toda a amostra, quando tratamos de materiais heterogêneos. Outra desvantagem é a sua dependência em relação ao método de referência, fraca sensibilidade aos componentes menores, transferência limitada de calibração entre os diferentes instrumentos, e particularmente é complicada a interpretação dos dados espectrais sendo necessário a utilização de análises multivariadas (ELMASRY; SUN; ALLEN, 2012; FENG et al., 2013; PASQUINI, 2018).

### **2.3. Imagem digital**

A imagem digital é composta de pixels que são pequenos elementos de imagem organizados em matriz. Cada pixel possui brilho e intensidade (nível de cinza) entre o preto e branco (matrizes bidimensionais) e é representado por um número, sendo a altura e largura da imagem definidas pelo conjunto de pixels nas direções Y e X. Imagens coloridas utilizam o espaço *RGB* (combinação de três matrizes), sendo cada uma das três matrizes representada na escala cinza, onde a absorção dos comprimentos de onda é referente ao vermelho, verde e azul. Assim cada pixel de uma imagem RGB apresenta três valores variando de 0 a 255, cada um indicando a ausência ou presença das três cores primárias.

Esta tecnologia de imagem proporciona uma alta resolução espacial e é desenvolvida como uma ferramenta de inspeção de qualidade e segurança, podendo facilmente avaliar e classificar produtos agrícolas. Recentemente tem sido aplicada para a avaliação visual da qualidade e classificação em carnes (BARBIN et al., 2016; BARBON et al., 2017; TRINDERUP et al., 2015; MUÑOZ et al., 2015), caracterização e conteúdo de gordura (ROMANO; MASI; CAVELLA, 2018; SERRANO et al., 2013), e outros alimentos (TAYLOR et al., 2018); para identificar rapidamente problemas de qualidade na linha de processamento com a mínima intervenção humana (FATHI; MOHEBBI; RAZAVI, 2011; QUEVEDO; AGUILERA; PEDRESCHI, 2010).

Atributos como tamanho, forma, cor e defeitos de textura na superfície podem ser facilmente avaliados por técnicas de imagem, mas a composição química, como conteúdo de umidade, gordura e proteína são dificilmente determinados com esta abordagem de imagem relativamente simples devido à informação espectral limitada (KAMRUZZAMAN et al., 2012b). As deficiências nas tecnologias de imagem digital e espectroscopia NIR podem ser

superadas por meio da introdução da técnica de imagem hiperespectral (KAMRUZZAMAN et al., 2013b; YANG; SUN; CHENG, 2017).

### **2.3.1. Processamento de imagens digitais**

O termo visão artificial consiste em associar uma câmera digital (aquisição de imagens) a um computador usado para o processamento de imagens.

**Segmentação-** Esta etapa é importante para extrair as características da imagem. Identifica a área de interesse para ser isolado.

**Crescimento de região-** É um processo iterativo de agrupamento de pixels com atributos comuns. Regiões homogêneas em relação ao atributo adjacentes, no espaço são agrupadas.

**Espaço da Cor-** O espaço da cor (ou modelo da cor) é uma especificação de um sistema de coordenadas e uma subestação dentro desse sistema no qual cada cor é representada por um único ponto. Em processamento de imagens, os modelos mais usados são o RGB (vermelho, verde e azul), CMY (ciano, magenta e amarelo) e o HSI (matiz, saturação e intensidade). Existem também o HSV (matiz saturação e brilho), e o HSL (matiz, saturação e luminosidade).

**Thresholding-** Também denominado como limiarização, é uma técnica utilizada para segmentar imagens de tons de cinzas que consiste em encontrar o limiar que agrupe os pixels das imagens em dois grupos de níveis diferentes (segundo e primeiro nível do limiar).

**Histograma-** É a representação em um gráfico cartesiano no qual o eixo horizontal reflete os valores das tonalidades de cinza que a imagem pode assumir enquanto o eixo vertical apresenta a frequência na qual essas tonalidades ocorrem. A limiarização muitas vezes baseia-se na utilização do histograma (NIXON; AGUADO, 2012; MARQUES FILHO; NETO, 1999; AZAVEDO; GRAFICA, 2003).

Diversos processamentos de imagens estão sendo utilizados em diversas pesquisas de alimentos para a medida da cor da carne (GIROLAMI et al., 2013), avaliação visual de salame italiano (ROMANO; MASI; CAVELLA, 2018), classificação de marmoreio em presunto curado (MUÑOZ et al., 2015).

## **2.4. Imagem hiperespectral**

A técnica de imagem hiperespectral é baseada no uso da plataforma de *hardware* e *software* integrados, combinando as técnicas de imagem e espectroscopia no infravermelho próximo (*NIR*), em um sistema que fornece simultaneamente informação espectral e espacial (*NIR-HSI*) (ELMASRY et al., 2011; KAMRUZZAMAN et al., 2015; LESIÓW; XIONG, 2013; XIONG et al., 2015c). A imagem é constituída por um bloco tridimensional de dados, composto de duas dimensões espaciais (*y* e *x*) e uma dimensão espectral ( $\lambda$ ) de comprimentos de onda.

É muito importante escolher a resolução espectral adequada, a fim de determinar a composição e as propriedades funcionais, bem como para a detecção de contaminantes em alimentos (CEN et al., 2016; CHELLADURAI et al., 2014). Para isso, o sistema de imagem hiperespectral deve ser calibrado para a distância (espacial) e comprimento de onda (espectral), e os valores de radiação (LAWRENCE et al., 2003). A calibração das imagens é realizada através de dois extremos de iluminação: "imagem de referência de branco" e "imagem escura". Os detectores da câmara geram sinais devido aos efeitos térmicos, mesmo quando não há nenhuma luz, o que é chamado de "corrente escura". A corrente escura é adicionada ao sinal produzido, por conseguinte, a imagem obtida deve ser corrigida subtraindo este sinal extra para posterior análise. Este procedimento permite compensar o deslocamento devido à corrente escura (LAWRENCE et al., 2003; NAGANATHAN et al., 2008).

Durante a última década, tem crescido o interesse por parte de pesquisadores ao redor do mundo em utilizar essa técnica, a fim de se obter análises não-destrutivas (CHENG; SUN, 2014; FENG et al., 2013; HE; SUN, 2015; SHAO et al., 2016; VINCKE et al., 2014; WOLD, 2016; YANG.; SUN; CHENG, 2017). No setor industrial as aplicações são feitas nas matérias-primas e no produto final, buscando sua qualidade e autenticação, além de trazer benefícios econômicos para a indústria e aumentar a confiança dos consumidores na qualidade do produto (ELMASRY; SUN; ALLEN, 2012). Esta técnica de imagem hiperespectral pode ser utilizada em uma diversidade de áreas, como a qualidade e segurança de inspeção de produtos agrícolas (DALE et al., 2013), arqueologia (VINCKE et al., 2014) e qualidade e segurança dos alimentos (HUANG et al., 2014; TAO; PENG, 2014).

O método de imagem hiperespectral *NIR* tem sido utilizada como uma análise não-destrutiva para a avaliação da qualidade e composição da carne suína (BARBIN et al., 2013; XIE et al., 2015, 2016), carne bovina (ELMASRY; SUN; ALLEN, 2013; NAGANATHAN et al., 2016), carne de cordeiro (KAMRUZZAMAN et al., 2013b; PU et al., 2014), peixe, camarão (CHENG; NICOLAI; SUN, 2017; CHENG; SUN, 2015b; DAI et al., 2016; HE; SUN, 2015; WOLD; KERMIT; SEGTMAN, 2016), carne de frango (KANDPAL et al., 2013; XIONG et

al., 2015a; YAVARI; HAMED; HAGHBIN, 2013), carne de peru (IQBAL; SUN; ALLEN, 2013).

A imensa quantidade de dados fornecida pelas técnicas espectroscópicas como o *NIR* e *NIR-HSI* necessita de métodos estatísticos de análise multivariada e ferramentas de visualização, para interpretar os dados espectrais a fim de extrair informações significativas de forma eficiente.

## 2.5. Quimiometria

A quimiometria utiliza ferramentas de estatística, matemática e gráficos para resolver sistemas químicos de múltiplas variáveis e pode ser útil para o planejamento e otimização de experimentos (SOUZA, 2013; FERREIRA 2015; MUNCK et al., 2010). A disseminação da quimiometria pode ser atribuída a dois fatores, a introdução de equipamentos que fornecem respostas que contêm grande quantidade de variáveis por amostra e o aumento de acesso aos computadores (GELADI; KOWALSKI, 1986).

Em geral, para trabalhar com a informação a partir da complexidade espectral e obter dados de ordem quantitativa e qualitativa dos espectros de imagem hiperespectral NIR, é necessário o uso de métodos quimiométricos multivariados. Estes métodos estão sendo desenvolvidos e disponibilizados em softwares como MATLAB (Mathworks, Inc.), Pirouette (Infometrix, Inc.), Statistica (Statsoft), Unscrambler (CAMO) e Octave ([www.octave.org](http://www.octave.org)).

### 2.5.1. Pré-tratamento dos dados

As informações extraídas dos espectros NIR podem ser compreendidas como um vetor ou como uma matriz de  $n$  linhas (amostras registradas) e  $m$  colunas (comprimentos de ondas). Antes da análise dos dados é necessário o pré-tratamento dos mesmos, para diminuir o ruído e acrescentar o sinal de interesse. A seleção do tratamento de dados deve proporcionar melhor discriminação entre as amostras e é realizada experimentalmente (a base de tentativa e erro). A seleção do tratamento dos dados depende das características das amostras a serem estudadas. Os métodos de pré-tratamentos dos dados mais utilizados são:

- **Média**- Em cada medição temos um alto número de registros de dados, logo, a média minimiza o ruído fornecendo um espectro limpo.

-**Centrados da média**- Extraí-se da variável o valor médio da mesma. Assim o valor de cada variável se refere ao centro do modelo:

$$X' = X_{i,j} - X_j \quad \text{Equação 8}$$

Onde  $X'$  é o dado centrado,

$X_{i,j}$  é o dado do espectro  $i$  e variável  $j$  antes do centrado,

$X_j$  é o promedio da coluna  $j$ .

**-Auto escalado-** Depois de centrados se dividem os valores pelo desvio padrão da variável. As variáveis têm media = 0 e desvio padrão = 1.

$$X' = (X_{i,j} - X_j)/S_j \quad \text{Equação 9}$$

Onde  $X'$  é o auto escalado,

$X_{i,j}$  é o dado da fila  $i$  (espectro  $i$ ) e a coluna  $j$  (variável  $j$ ) antes do auto escalado,

$X_j$  é a média da coluna  $j$ ,

$S_j$  é o desvio padrão da coluna.

**- Variável padrão normal (SNV - *Standard Normal Variate*)-** Corrige o efeito de dispersão produzido, por exemplo, em diferenças espectrais no tamanho de partícula de amostras sólidas, minimizando as variações de deslocamento da linha de base. Está baseado em subtrair de cada variável obtida (absorbância) a média da variável e dividir o valor com o desvio padrão.

$$X'^{SNV} = (X_{i,j} - X_i)/S_i \quad \text{Equação 10}$$

$X'^{SNV}$  é a variável padrão normal,

$X_{i,j}$  é o dado da fila  $i$  (espectro  $i$ ) e a coluna  $j$  (variável  $j$ ) antes do auto escalado,

$X_i$  é a média da fila  $i$ ,

$S_i$  é o desvio padrão da fila.

**- Correção do espalhamento multiplicativo (*MSC multiplicative scatter correction*)-** Este método é aplicado com a finalidade de corrigir os efeitos de espalhamento aditivos e multiplicativos na absorbância nos espectros obtidos da espectroscopia. Esses efeitos de espalhamento são causados por fenômenos físicos, como mudanças no caminho ótico, na sensibilidade do detector e do amplificador, variações de temperatura e na pressão e heterogeneidade da amostra. Este método remove o efeito pela linearização de cada espectro em função de um espectro de referência. Aplicando uma regressão linear para calcular o

coeficiente angular e linear do gráfico entre o espectro ideal e o espectro que será corrigido. O espectro corrigido é calculado subtraindo cada ponto do espectro pelo valor do coeficiente linear dividindo este valor pelo coeficiente angular.

**-Derivadas-** Permite aumentar as diferenças entre as bandas sobrepostas das bandas largas dos espectros. A primeira derivada minimiza as diferenças do deslocamento da linha de base e a segunda derivada minimiza diferenças de inclinação. A escolha de pontos de suavização deve ser avaliada, pois grandes intervalos fazem pequenas diferenças nos espectros e fazem com que o ruído seja menor.

Depois do tratamento dos dados é possível aplicar métodos multivariados que ajudam a classificar os dados em grupos ou padrões e a identificar variáveis que influenciem no sistema, permitindo a visualização de tendências dos dados. (SOUZA, 2013; FERREIRA 2015).

## 2.5.2. Métodos de reconhecimento de padrões não supervisionados

### 2.5.2.1. Análise de componentes principais

A análise de componentes principais (*PCA*) decompõe a matriz de espectros infravermelhos para um número menor de dados em um novo sistema de coordenadas. É uma análise exploratória de um conjunto de dados que permite extrair o máximo de informações através da relação entre as amostras (linhas de uma matriz) e as variáveis (colunas de uma matriz) (BEEBE; KOWALSKI, 1987). A Figura 3 apresenta a decomposição da matriz  $X$  de dimensão ( $d \times b$ ) pela análises de componentes principais até  $S$  componentes principais




Figura 3. Esquema da decomposição por *PCA*.

FONTE: GELADI; KOWALSKI (1986).

Esta matriz ( $M_h$ ), pode ser escrita como um produto de dois vetores, escores (*scores*)  $t_h$  e peso (*loadings*)  $p_h$  para um número igual a "s" componentes principais.

$$X = t_1 p_1^l + t_2 p_2^l + \cdots t_s p_s^l + E \quad \text{Equação 11}$$

Outra maneira de escrever a equação 11 é:

$$X = TP^l + E \quad \text{Equação 12}$$

$X$  é o conjunto original de dados com  $d$  linhas (amostras),

$P$  colunas (variáveis),

$T$  é a matriz de *scores*.

*Scores* é o número de componentes principais coordenados no novo sistema de eixos e  $P$  é a matriz de pesos (informa quanto contribui cada variável original para a formação dos novos eixos). O novo conjunto de variáveis (componentes principais) é a resultante da combinação linear das variáveis originais. Os novos eixos são ortogonais um ao outro e estão ordenados em forma decrescente em relação à parcela da variância dos dados originais descrita. Assim, podemos dizer que PCA serve para agrupar as variáveis altamente correlacionadas em uma nova variável chamada componente principal (SOUZA, 2013; GEMPERLINE, 2006). Normalmente a maior fração da variância é descrita pelos primeiros componentes principais, sendo que os dados são visualizados pelo gráfico dos *scores* de um componente *versus* o outro.

### 2.5.2.2. Regressão por mínimos quadrados parciais (PLS)

Uma das importantes ferramentas estatísticas de análise quantitativa de dados multivariada é a regressão por mínimos quadrados parciais (PLS), que tem sido aplicada devido as suas vantagens sobre os métodos mais antigos de calibração, como *CLS* (mínimos quadrados clássica), *ILS* (mínimos quadrados inversos) e *PCR* (regressão de componentes principais).

O método é baseado na relação linear entre as variáveis instrumentais ( $X$ ) e variáveis de interesse ( $Y$ ), sendo utilizadas simultaneamente na fase de calibração. A matriz é decomposta em matrizes de variações dos espectros (*loadings* ou pesos) e a posição das amostras (*scores*) (GELADI & KOWALSKI, 1986) e calcula-se nas equações 13 e 14 os espaços dos preditores ( $X$ ) caracterizado pela covariância com a máxima variável de resposta ( $Y$ ) (FENG et al., 2013; OLIVERI et al., 2014).

$$X = TP^l + E_x = \sum t_h p_h + E_x \quad \text{Equação 13}$$

$$Y = UQ^l + E_y = \sum u_h q_h + E_y \quad \text{Equação 14}$$

X é a matriz de dados (medida instrumental),

Y é a matriz de resposta (concentração por exemplo),

T e U são os *scores* para as duas matrizes de dados,

P e Q são os pesos,

$E_x$  e  $E_y$  são os resíduos compostos pelas variáveis descartadas,

$h$  é número de variáveis latentes (VL), isto é, as matrizes que contêm a parte não modelada (MILLER; MILLER, 2000; BEEBE; PELL; SEASHOLTZ, 1998). Uma relação linear é estabelecida entre os escores de X e os escores de Y para cada VL, representada pela equação 15.

$$U_h = b_h T_h \quad \text{Equação 15}$$

$b_h$  é o vetor de coeficientes de regressão do modelo linear para cada VL e é obtido através da equação 16

$$b_h = \frac{u_{ht_h}^l}{t_{ht_h}^l} \quad \text{Equação 16}$$

Existem algoritmos como o *NIPALS* (*Non-linear Iterative Partial Least Squares*) que fazem os cálculos anteriores onde, ao final do processo, a variância explicada pela primeira VL será maior que a variância explicada pela segunda VL e assim sucessivamente até um número de VL's definido e o algoritmo converge rapidamente (NETO, 2005).

Após a obtenção do modelo de calibração, um passo importante é a validação do modelo obtido. A validação cruzada é normalmente utilizada para obtenção de modelos confiáveis de calibração, podendo ser posteriormente revalidado utilizando validação externa. A validação é feita com base na avaliação da grandeza dos erros de previsão comparando os valores das variáveis dependentes do conjunto de amostras de calibração com as suas previsões, quando eles não participam na construção do modelo de calibração. Na validação cruzada *leave-one-out*, o PLS separa uma das amostras de calibração e usa como amostra de validação. Isto é feito seguidamente para cada amostra até que todas as amostras de calibração sejam utilizadas como amostra de validação (SOUZA, 2013).

Posteriormente é feita a validação com conjunto externo que deve apresentar amostras com valores que compreendem os intervalos do conjunto de dados que deverá proporcionar um desempenho semelhante. Não há um número fixo de amostras necessárias para o desenvolvimento de calibração, mas alguns autores indicam números entre 20 e 30 amostras para facilitar o estudo e iniciar a calibração (WILLIAMS & NORRIS, 2001). A norma 1665-5 ASTM ("ASTM" 2012) sugere certo número de amostras suficiente para definir a relação entre as variáveis espectrais e a concentração do componente de interesse. Se as amostras têm um grande número de componentes com elevada variabilidade, será necessário um grande número de amostras para desenvolvimento do modelo. Segundo De Souza et al. (2014), para os modelos de calibração construídos o número mínimo de amostras para a calibração deve ser igual a  $6(k + 1)$  para dados médios (onde  $k$  é o número de variáveis latentes) e o conjunto de predição deve ser igual a  $4k$ , para o modelo PLS.

Após o desenvolvimento do modelo será possível definir o número de variáveis espectrais necessário para a calibração. O objetivo da maioria das análises multivariadas é desenvolver modelos para prever uma propriedade de interesse (FERREIRA, 2015).

### **2.5.3. Métodos de classificação supervisionados**

Estas técnicas são usadas para identificar as semelhanças e as diferenças entre diferentes tipos de amostras, tendo como objetivo a construção de modelos de classificação onde a propriedade é a categoria (discreta). *A priori* é necessário saber quais amostras são semelhantes e quais são diferentes para encontrar os critérios de classificação. Nas análises supervisionadas, seleciona-se uma série de amostras representativas de cada classe, para realizar as medidas experimentais. Os métodos mais utilizados são: *k-NN*, o método *SIMCA* e os dois métodos de análise discriminante: *LDA* e *PLS-DA*.

#### **2.5.3.1. Análises Discriminante Linear (LDA)**

A análise discriminante linear (*LDA*) é uma técnica de classificação supervisionada onde o número de categorias e as amostras que pertencem a cada categoria são previamente definidos. O método fornece uma série de funções discriminantes lineares ortogonais, igual ao número de categorias menos uma, que permitem que as amostras sejam classificadas em uma ou outra categoria maximizando a variância entre categorias e minimizando o índice de variação entre as classes. É um método estatístico que poderia determinar a que grupo pertence a amostra. Tomando o logaritmo natural de probabilidades posteriores, dá a cada grupo uma

função de classificação linear nas variáveis originais (HAI, WANG, 2006; COZZOLINO et al., 2006). É a melhor opção para o tratamento de dados instrumentais, especialmente aqueles com um grande número de variáveis e que assumem que as classes são linearmente separadas, porém possuem algumas desvantagens, sendo incapaz de identificar e lidar com amostras atípicas de maneira satisfatória, apresenta dificuldades quando o número de classes se torna grande e são sensíveis às colinearidades (FERREIRA, 2015).

#### **2.5.3.2. Modelamento suave independente de analogia de classes (*SIMCA*)**

*SIMCA* é um dos métodos de classificação mais utilizados na quimiometria (ADELINE et al., 2017; GÓMEZ-DE-ANDA et al., 2012). Assume-se que os valores medidos para um grupo de amostras parecidas tenderão para uma distribuição uniforme e modelável. Aumentando número de amostras, essa distribuição uniforme se torna cada vez mais visível. Esta técnica requer o conhecimento prévio das categorias que as amostras pertencem, permitindo estimar o grau de probabilidade. O *SIMCA* é baseado nos modelos de componentes principais sendo ajustado a cada classe do conjunto de dados, originando um classificador para cada classe. Para maximizar a capacidade preditiva dos modelos individuais em relação ao conjunto de dados modelado para cada classe é necessário fazer uma validação cruzada. Uma característica interessante do método *SIMCA* é o fato de construir um modelo independente para cada classe. Se for necessária a inclusão de uma nova classe, ela pode ser adicionada independentemente do modelo já existente, sem necessidade de repetir todo o processo de modelagem (FERREIRA, 2015; GÓMEZ-DE-ANDA et al., 2012).

#### **2.6. Aprendizado de máquina (*ML - machine learning*)**

O aprendizado de máquina tem por objetivo desenvolver algoritmos e técnicas computacionais os quais permitem que o computador seja capaz de aprender os processos (GOLDSCHMIDT, 2010). Este aprendizado está relacionado ao reconhecimento automático de padrões a partir de um determinado banco de dados de treinamento e generalizações. Essa relação pode ser usada para interpretar novos dados, testes, para a tomada de decisões e previsões (NOLASCO PEREZ et al., 2018; SHERLOCK; SMITH; MITCHELL, 1996). Assim quando utilizamos os dados da amostra, o sistema de aprendizado pode gerar uma base atualizada para melhorar a classificação dos dados subsequentes da mesma fonte, e expressar a nova base em forma simbólica inteligível (MICHIE, 1991).

Nos principais algoritmos em aprendizado de máquina, o modelo de conhecimento é abstraído a partir de sucessivas iterações sobre o conjunto de dados ou exemplos históricos disponíveis e podem ser subdivididos em:

**Aprendizado Supervisionado** - Os dados disponíveis devem conter a informação esperada a ser produzida pelo modelo que está sendo construído. Entre eles temos Random Forest (*RF*) e *Support Vector Machine* (*SNV*)

**Aprendizado Não Supervisionado** - Os algoritmos procuram agrupar os dados em função da similaridade que eles apresentem entre si. Desta forma, os dados mais similares tendem a ficar em um mesmo grupo, enquanto que dados diferentes tendem a ser organizados em grupos distintos (GOLDSCHMIDT, 2010).

**Aprendizado de reforço** - O algoritmo aprende observando o mundo ao seu redor. A informação de entrada é o *feedback* ou retroalimentação que obteve do mundo exterior em resposta às suas ações. Portanto, o sistema aprende com base na tentativa e erro.

Atualmente estão sendo pesquisadas as técnicas de aprendizado de máquina como ferramenta na área dos alimentos como qualidade e classificação de alimentos mediante a análise dos dados de espectroscopia NIR, imagem digital e NIR-HSI (ELLIS; BROADHURST; GOODACRE, 2004; LIU; YANG; DENG, 2015; NOURI-AHMADABADI et al., 2017; ZHENG; FU; YING, 2014).

### 2.6.1. Floresta Aleatoria (*RF* - *Random Forest*)

Este método proposto por Breiman (2001), é um algoritmo de aprendizado de máquina supervisionado que utiliza um conjunto de árvores de classificações. O número de atributos em cada nó e o número de árvore é definido pelo usuário. Cada árvore usa um conjunto de treinamento (dois terços do conjunto de dados) totalmente diferente, composto por instâncias de amostragem aleatória. É considerado um classificador computacional eficiente somente quando cada árvore é construída independente uma da outra (BARBON et al., 2016; ROPODI; PANAGOU; NYCHAS, 2017). Pode ser usado para resolver problemas de classificação e regressão através de uma multiplicidade de árvores de decisão (CHEMURA; MUTANGA; DUBE, 2017). Este algoritmo está sendo usado em diversas áreas de pesquisas devido as suas altas precisões, sua capacidade de lidar com dados altamente não lineares, robustez ao ruído e simplicidade ao ajuste (CHEMURA; MUTANGA; DUBE, 2017; LEBEDEV et al., 2014; RODRIGUEZ-GALIANO et al., 2012).

### 2.6.2. Máquina de vetores de suporte (SVM - *Support Vector Machine*)

SVM constrói um hiperplano ideal ou conjunto de hiperplanos em um espaço de alta dimensão sendo ideal para separar os objetos de diferentes classes. Quando o limite linear no espaço de entrada não é suficiente para separar as classes, converte dados do espaço de entrada de baixa em um espaço de caractere de alta dimensão usando as funções de Kernel para manipular a não linearidade dos dados. (ZHENG; FU; YING, 2014). A margem funcional é uma boa separação pelo hiperplano com maior distância entre dois pontos, que separa dois grupos.

### Referências

ADELINE, K. R. M.; GOMEZ, C.; GORRETTA, N.; ROGER, J. M. Predictive ability of soil properties to spectral degradation from laboratory Vis-NIR spectroscopy data. **Geoderma**, v. 288, p. 143-153, 2017.

ALAMPRESE, C.; FONGARO, L.; CASIRAGHI, E. Effect of fresh pork meat conditioning on quality characteristics of salami. **Meat Science**, v. 119, p. 193–198, 1 set. 2016.

ALEXANDRAKIS, D.; DOWNEY, G.; SCANNELL, A. G. M. Rapid Non-destructive Detection of Spoilage of Intact Chicken Breast Muscle Using Near-infrared and Fourier Transform Mid-infrared Spectroscopy and Multivariate Statistics. **Food and Bioprocess Technology**, v. 5, n. 1, p. 338–347, 9 jan. 2012.

AZEVEDO, E. CONCI; GRÁFICA, A. **Computação. Teoria e Prática.**—Ed. 2003.

BALAGE, J. M.; E SILVA, S. D. L.; GOMIDE, C. A., DE NADAI BONIN, M.; & FIGUEIRA, A. C. Predicting pork quality using Vis/NIR spectroscopy. **Meat science**, v. 108, p. 37-43, out. 2015.

BARBIN, D. F.; ELMASRY, G.; SUN, D. W.; ALLEN, P. Non-destructive determination of chemical composition in intact and minced pork using near-infrared hyperspectral imaging. **Food Chemistry**, v. 138, n. 2–3, p. 1162-1171, 1 jun. 2013.

BARBIN, D. F.; KAMINISHIKAWAHARA, C. M.; SOARES, A. L.; MIZUBUTI, I. Y.; GRESPAN, M.; SHIMOKOMAKI, M.; HIROOKA, E. Y. Prediction of chicken quality attributes by near infrared spectroscopy. **Food Chemistry**, v. 168, p. 554-560, 1 fev. 2015. doi: 10.1016/j.foodchem.2014.07.101.

BARBIN, D. F., MASTELINI, S. M., BARBON JR, S., CAMPOS, G. F., BARBON, A. P. A., & SHIMOKOMAKI, M. Digital image analyses as an alternative tool for chicken quality assessment. **Biosystems Engineering**, v. 144, p. 85–93, 2016.

BARBON, A. P. A.; BARBON JR, S.; MANTOVANI, R. G.; FUZYI, E. M., PERES, L. M.; BRIDI, A. M. Storage time prediction of pork by Computational Intelligence. **Computers and**

**Electronics in Agriculture**, v. 127, p. 368–375, 2016.

BARBON, A. P. A.; BARBON JR, S.; CAMPOS, G. F. C.; SEIXAS JR, J. L.; PERES, L. M.; MASTELINI, S. M.; Andreo, N; ULRICI A.; BRIDI, A. M. Development of a flexible Computer Vision System for marbling classification. **Computers and Electronics in Agriculture**, v. 142, p. 536–544, 1 nov. 2017.

BARBUT, S. Poultry products processing an industry guide. Editorial **CRC Press**, p. 173-178. 2002.

BEEBE, K. R.; PELL, R. J.; SEASHOLTZ, M. B. Chemometrics: A practical guide. New York: Wiley. 1998.

BEEBE, K. R.; KOWALSKI, B. R. An introduction to multivariate calibration and analysis. **Analytical Chemistry**, 59(17), 1007A-1017A. 1987.

BOWKER, B.; HAWKINS, S.; ZHUANG, H. Measurement of water-holding capacity in raw and freeze-dried broiler breast meat with visible and near-infrared spectroscopy. **Poultry Science**, v. 93, n. 7, p. 1834–1841, 2014.

BRANDELLI, A.; SALA, L.; KALIL, S. J. Microbial enzymes for bioconversion of poultry waste into added-value products. **Food Research International**, v. 73, p. 3–12, 1 jul. 2015.

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

CEN, H.; LU, R.; ZHU, Q.; MENDOZA, F. Nondestructive detection of chilling injury in cucumber fruit using hyperspectral imaging with feature selection and supervised classification. **Postharvest Biology and Technology**, v. 111, p. 352-361, jan. 2016.

CHELLADURAI, V., KARUPPIAH, K., JAYAS, D. S., FIELDS, P. G., & WHITE, N. D. G. Detection of *Callosobruchus maculatus* (F.) infestation in soybean using soft X-ray and NIR hyperspectral imaging techniques. **Journal of Stored Products Research**, v. 57, p. 43–48, abr. 2014.

CHEMURA, A.; MUTANGA, O.; DUBE, T. Remote sensing leaf water stress in coffee (*Coffea arabica*) using secondary effects of water absorption and random forests. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 100, p. 317–324, 1 ago. 2017.

CHENG, J.-H.; NICOLAI, B.; SUN, D.-W. Hyperspectral imaging with multivariate analysis for technological parameters prediction and classification of muscle foods: A review. **Meat Science**, v. 123, p. 182–191, 1 jan. 2017.

CHENG, J.-H.; SUN, D.-W. Hyperspectral imaging as an effective tool for quality analysis and control of fish and other seafoods: Current research and potential applications. **Trends in Food Science & Technology**, v. 37, n. 2, p. 78–91, 1 jun. 2014.

CHENG, J.-H.; SUN, D.-W. Data fusion and hyperspectral imaging in tandem with least squares-support vector machine for prediction of sensory quality index scores of fish fillet. **LWT - Food Science and Technology**, v. 63, n. 2, p. 892–898, out. 2015b.

CHIESA, L. et al. Authentication of Italian PDO lard using NIR spectroscopy, volatile profile and fatty acid composition combined with chemometrics. **Food Chemistry**, v. 212, 2016.

COZZOLINO, D.; VADELL, A.; BALLESTEROS, F.; GALIETTA, G.; BARLOCCO, N. Combining visible and near-infrared spectroscopy with chemometrics to trace muscles from an autochthonous breed of pig produced in Uruguay: A feasibility study. **Analytical and Bioanalytical Chemistry**, v. 385, n. 5, p. 931-936, 2006.

DAI, Q.; CHENG, J. H.; SUN, D. W.; ZHU, Z.; ; PU, H. Prediction of total volatile basic nitrogen contents using wavelet features from visible/near-infrared hyperspectral images of prawn (*Metapenaeus ensis*). **Food Chemistry**, v. 197, n. Pt A, p. 257–65, 15 abr. 2016.

DALE, L. M.; THEWIS, A.; BOUDRY, C., ROTAR, I.; DARDENNE, P.; BAETEN, V.; ; PIERNA, J. A. F. Hyperspectral Imaging Applications in Agriculture and Agro-Food Product Quality and Safety Control: A Review. **Applied Spectroscopy Reviews**, v. 48, n. 2, p. 142–159, 2013.

DALLA COSTA, F. A.; DE CASTRO TAVERNARI, F.; DALLA COSTA, O. A.; DE CASTRO, F. F.; REMUS, A. Enriquecimento com ácidos graxos da série ômega 3 em carne de aves e ovos. **Pubvet**, v. 11, p. 103-206. 2016.

DE OLIVEIRA, G. Abatedouro de Aves - Brasil Foods SAA Universidade Tecnológica. Estagio Supervisionado. **Federal do Paraná Campus – Campo Mourão Coordenação de Engenharia de Alimentos**. 19 pag.2014

ELLIS, D. I.; BROADHURST, D.; GOODACRE, R. Rapid and quantitative detection of the microbial spoilage of beef by Fourier transform infrared spectroscopy and machine learning. **Analytica Chimica Acta**, v. 514, n. 2, p. 193–201, 1 jul. 2004.

ELMASRY, G.; IQBAL, A.; SUN, D. W.; ALLEN, P., ; WARD, P. Quality classification of cooked , sliced turkey hams using NIR hyperspectral imaging system. **Journal of Food Engineering**, v. 103, n. 3, p. 333-344, 2011.

ELMASRY, G.; SUN, D.-W.; ALLEN, P. Near-infrared hyperspectral imaging for predicting colour, pH and tenderness of fresh beef. **Journal of Food Engineering**, v. 110, n. 1, p. 127-140, maio 2012.

ELMASRY, G.; SUN, D.-W.; ALLEN, P. Chemical-free assessment and mapping of major constituents in beef using hyperspectral imaging. **Journal of Food Engineering**, v. 117, n. 2, p. 235-246, jul. 2013.

FATHI, M.; MOHEBBI, M.; RAZAVI, S. M. A. Application of Image Analysis and Artificial Neural Network to Predict Mass Transfer Kinetics and Color Changes of Osmotically Dehydrated Kiwifruit. **Food and Bioprocess Technology**, v. 4, n. 8, p. 1357–1366, 2011.

FENG, Y. Z.; ELMASRY, G.; SUN, D. W.; SCANNELL, A. G.; WALSH, D.; MORCY, N. Near-infrared hyperspectral imaging and partial least squares regression for rapid and reagentless determination of Enterobacteriaceae on chicken fillets. **Food chemistry**, v. 138, n. 2-3, p. 1829–36, 1 jun. 2013.

FERREIRA, Marcia Miguel Castro. Quimiometria: conceitos, métodos e aplicações. **Campinas, SP: Editora da Unicamp**, v. 496, 2015.

FONGARO, L.; ALAMPRESE, C.; CASIRAGHI, E. Ripening of salami: assessment of colour and aspect evolution using image analysis and multivariate image analysis. **Meat science**, v.

101, p. 73–7, mar. 2015.

GELADI, P.; KOWALSKI, B. R. Partial least-squares regression: a tutorial. **Analytica Chimica Acta**, v. 185, p. 1–17, 1 jan. 1986.

GEMPERLINE, P. J. Principal component analysis PCA. In: GEMPERLINE, P. J. (Ed.). *Practical Guide to Chemometrics*. Second ed. [S.l.] CRC Press, p. 69-104. 2006.

GIARETTA, N. et al. Myoglobin as marker in meat adulteration: A UPLC method for determining the presence of pork meat in raw beef burger. **Food Chemistry**, v. 141, n. 3, p. 1814–1820, 1 dez. 2013.

GIROLAMI, A.; NAPOLITANO, F.; FARAONE, D.; BRAGHIERI, A. Measurement of meat color using a computer vision system. **Meat Science**, v. 93, n. 1, p. 111-118, 1 jan. 2013.

GOLDSCHMIDT, RONALDO RIBEIRO. "Uma Introdução à Inteligência Computacional: fundamentos, ferramentas e aplicações." **Rio de Janeiro Brasil: IST-Rio**. p. 32. 2010.

GÓMEZ-DE-ANDA, F.; DORANTES-ÁLVAREZ, L.; GALLARDO-VELÁZQUEZ, T.; OSORIO-REVILLA, G.; CALDERÓN-DOMÍNGUEZ, G.; LABAT, P. M.; DE-LA-ROSA-ARANA, J. L. Determination of *Trichinella spiralis* in pig muscles using Mid-Fourier Transform Infrared Spectroscopy (MID-FTIR) with Attenuated Total Reflectance (ATR) and Soft Independent Modeling of Class Analogy (SIMCA). **Meat Science**, v. 91, n. 3, p. 240-246, jul. 2012.

HAI, Z.; WANG, J. Electronic nose and data analysis for detection of maize oil adulteration in sesame oil, **Sensors Actuators B: Chemical**, 119: 449–455, 2006

HE, H.-J.; SUN, D.-W. Hyperspectral imaging technology for rapid detection of various microbial contaminants in agricultural and food products. **Trends in Food Science & Technology**, v. 46, n. 1, p. 99–109, nov. 2015.

HERNÁNDEZ-CHÁVEZ, J. F., GONZÁLEZ-CÓRDOVA, A. F., RODRÍGUEZ-RAMÍREZ, R., & VALLEJO-CORDOBA, B. et al. Development of a polymerase chain reaction and capillary gel electrophoresis method for the detection of chicken or turkey meat in heat-treated pork meat mixtures. **Analytica Chimica Acta**, v. 708, n. 1–2, p. 149–154, 5 dez. 2011.

HUANG, H.; LIU, L.; NGADI, M. O.; & GARIÉPY, C. Rapid and non-invasive quantification of intramuscular fat content of intact pork cuts. **Talanta**, v. 119, 2014.

HSU, C. P. S. Infrared Spectroscopy. In: SETTLE, F. A. (Ed.). *Handbook of Instrumental Techniques for Analytical Chemistry*. First ed. Michigan: **Prentice Hall PTR**, 1997. p. 257-283. 1997.

IQBAL, A.; SUN, D.-W.; ALLEN, P. Prediction of moisture, color and pH in cooked, pre-sliced turkey hams by NIR hyperspectral imaging system. **Journal of Food Engineering**, v. 117, n. 1, p. 42–51, jul. 2013.

JIANG, H.; YOON, S. C.; ZHUANG, H.; WANG, W.; LAWRENCE, K. C.; YANG, Y. Tenderness classification of fresh broiler breast fillets using visible and near-infrared hyperspectral imaging. **Meat Science**, v. 139, p. 82–90, 1 maio 2018.

KAMRUZZAMAN, M.; BARBIN, D.; ELMASRY, G.; SUN, D. W.; ALLEN, P. Potential of hyperspectral imaging and pattern recognition for categorization and authentication of red meat. **Innovative Food Science & Emerging Technologies**, v. 16, p. 316–325, out. 2012b.

KAMRUZZAMAN, M.; ELMASRY, G.; SUN, D. W.; ALLEN, P. Non-destructive assessment of instrumental and sensory tenderness of lamb meat using NIR hyperspectral imaging. **Food Chemistry**, v. 141, n. 1, 2013.

KAMRUZZAMAN, M.; MAKINO, Y.; OSHITA, S. Rapid and non-destructive detection of chicken adulteration in minced beef using visible near-infrared hyperspectral imaging and machine learning. **Journal of Food Engineering**, v. 170, p. 8–15, 1 fev. 2016.

KAMRUZZAMAN, M.; MAKINO, Y.; OSHITA, S.; LIU, S. Assessment of Visible Near-Infrared Hyperspectral Imaging as a Tool for Detection of Horsemeat Adulteration in Minced Beef. **Food and Bioprocess Technology**, v. 8, n. 5, p. 1054–1062, 1 maio 2015.

KANDPAL, L. M.; LEE, H.; KIM, M. S.; MO, C.; CHO, B. K. Hyperspectral reflectance imaging technique for visualization of moisture distribution in cooked chicken breast. **Sensors (Basel, Switzerland)**, v. 13, n. 10, 2013.

LAWRENCE, K. C. et al. *C p h i s a i*. v. 46, n. 2, p. 513–521, 2003.

LEBEDEV, A. V.; WESTMAN, E.; VAN WESTEN, G. J. P.; KRAMBERGER; M. G., LUNDERVOLD, A.; AARSLAND, D.; ...; VELLAS, B. Random Forest ensembles for detection and prediction of Alzheimer's disease with a good between-cohort robustness. **NeuroImage: Clinical**, v. 6, p. 115–125, 1 jan. 2014.

LESIÓW, T.; XIONG, Y. L. A simple, reliable and reproductive method to obtain experimental pale, soft and exudative (PSE) pork. **Meat science**, v. 93, n. 3, p. 489–94, mar. 2013.

LIU, C.; YANG, S. X.; DENG, L. Determination of internal qualities of Newhall navel oranges based on NIR spectroscopy using machine learning. **Journal of Food Engineering**, v. 161, p. 16–23, 1 set. 2015.

MADEIRA, L. A.; SARTORI, J. R.; SALDANHA, É. S. P. B.; PIZZOLANTE, C. C.; SILVA, M. D. P.; MENDES, A. A.; Takahashi, S. E; SOLARTE, W. V. N. Morfologia das fibras musculares esqueléticas de frangos de corte de diferentes linhagens criados em sistemas de confinamento e semiconfinamento. **Revista Brasileira de Zootecnia**, v. 35, n. 6, p. 2322–2332, 2006.

MANDLI, J., FATIMI, I. E.; SEDDAOUI, N.; AMINE, A. Enzyme immunoassay (ELISA/immunosensor) for a sensitive detection of pork adulteration in meat. **Food Chemistry**, v. 255, p. 380–389, 30 jul. 2018.

MARQUES FILHO, OGÊ; NETO, HUGO VIEIRA. **Processamento digital de imagens**. Brasport, 1999.

MICHIE, D. Methodologies from Machine Learning in Data Analysis and Software. **The Computer Journal**, v. 34, n. 6, p. 559–565, 1991.

MILLER, J. N.; MILLER, J. C. Statistics and Chemometrics for Analytical Chemistry. London: Prentice Hall. 2000.

MOREIRA, É. L. S. Composição Centesimal e Aspectos Físicos da Carne do Peito, da Coxa e da Sobrecoxade Frangos Alimentados com Dietas Contendo Erva- Mate (*Ilex paraguariensis*). Trabalho de Conclusão do curso em Medicina Veterinária. **Universidade de Brasília Faculdade de agronomia e Medicina Veterinária**, pag. 42. 2015.

MUNCK, L.; JESPERSEN, B. M.; RINNAN, Å.; SEEFELDT, H. F.; ENGELSEN, M. M., NØRGAARD, L.; ENGELSEN, S. B. A physiochemical theory on the applicability of soft mathematical models-experimentally interpreted. **Journal of Chemometrics**, v. 24, n. 7–8, 2010.

MUÑOZ, I.; RUBIO-CELORIO, M.; GARCIA-GIL, N.; GUÀRDIA, M. D.; FULLADOSA, E. Computer image analysis as a tool for classifying marbling: A case study in dry-cured ham. **Journal of Food Engineering**, v. 166, p. 148–155, 1 dez. 2015.

MEYER, G. E.; SUBBIAH, J. Three dimensional chemometric analyses of hyperspectral images for beef tenderness forecasting. **Journal of Food Engineering**, v. 169, p. 309–320, jan. 2016.

NAGANATHAN, G. K.; GRIMES, L. M.; SUBBIAH, J.; CALKINS, C. R.; SAMAL, A.; MEYER, G. E. Partial least squares analysis of near-infrared hyperspectral images for beef tenderness prediction. **Sensing and Instrumentation for Food Quality and Safety**, v. 2, n. 3, p. 178–188, 2008.

NAGANATHAN, G. K.; CLUFF, K.; SAMAL, A.; CALKINS, C. R.; JONES, D. D.; MEYER, G. E.; SUBBIAH, J. Three dimensional chemometric analyses of hyperspectral images for beef tenderness forecasting. **Journal of Food Engineering**, v. 169, p. 309–320, jan. 2016.

NETO, B. W. Parâmetros de qualidade de lubrificantes e óleo de oliva através de espectroscopia vibracional, calibração multivariada e seleção de variáveis / Tese – **Universidade Estadual de Campinas, Instituto de Química**. p. 130, 2005.

NIXON, Mark S.; AGUADO, Alberto S.. **Feature Extraction & Image Processing for Computer Vision**. 3. Ed. 2000.

NOLASCO PEREZ, I. M.; BADARÓ, A. T.; BARBON JR, S.; BARBON, A. P. A.; POLLONIO, M. A. R.; BARBIN, D. F. Classification of Chicken Parts Using a Portable Near-Infrared (NIR) Spectrophotometer and Machine Learning. **Applied Spectroscopy**, v. 0, n. 0, p. 370281878887, 2018.

NOURI-AHMADABADI, H.; OMID, M.; MOHTASEBI, S. S.; FIROUZ, M. S. Design, development and evaluation of an online grading system for peeled pistachios equipped with machine vision technology and support vector machine. **Information Processing in Agriculture**, v. 4, n. 4, p. 333-341, 1 dez. 2017.

OLIVERI, P.; LÓPEZ, M. I.; CASOLINO, M. C.; RUISÁNCHEZ, I.; CALLAO, M. P.; MEDINI, L.; LANTERI, S. Partial least squares density modeling (PLS-DM) – A new class-modeling strategy applied to the authentication of olives in brine by near-infrared spectroscopy. **Analytica Chimica Acta**, v. 851, p. 30-36, 3 dez. 2014.

OSBORNE, B. G., FEARN, T., HINDLE, P. H. Practical NIR spectroscopy with applications in food and beverage analysis, 2nd. ed. New York, USA: Longman Scientific & Technical, p. 227.1993

PASQUINI, C. Near infrared spectroscopy: Fundamentals, practical aspects and analytical applications. **Journal of the Brazilian Chemical Society**, v. 14, n. 2, p. 198–219, 2003.

PASQUINI, C. Near infrared spectroscopy: A mature analytical technique with new perspectives – A review. **Analytica Chimica Acta**, v. 1026, p. 8–36, 5 out. 2018.

PINO, L. M. (ESCOLA S. DE A. "LUIZ DE Q. U. DE S. P. **Estabilidade oxidativa da carne de frangos alimentados com diferentes fontes lipídicas, armazenada sob congelamento**. pag. 72. 2005.

PINTO, L. A. D. M.; PINTO, M. D. M.; BOVO, J.; MATEUS, G. A. P.; TAVRES, F. D. O.; BAPTISTA, A. T. A.; HIRATA, A. K. Aspectos ambientais do abate de aves: uma revisão. **Revista UNINGÁ REVIEW**, v. 22, n. 3, p. 44–50, 2015.

PRIETO, N.; LOPEZ-CAMPOS, O.; AALHUS, J. L.; DUGAN, M. E. R., JUAREZ, M.; UTTARO, B. Use of near infrared spectroscopy for estimating meat chemical composition, quality traits and fatty acid content from cattle fed sunflower or flaxseed. **Meat science**, v. 98, n. 2, p. 279–88, out. 2014.

PU, H.; SUN, D. W.; MA, J.; LIU, D.; KAMRUZZAMAN, M. Hierarchical variable selection for predicting chemical constituents in lamb meats using hyperspectral imaging. **Journal of Food Engineering**, v. 143, 2014.

PULLANAGARI, R. R.; YULE, I. J.; AGNEW, M. On-line prediction of lamb fatty acid composition by visible near infrared spectroscopy. **Meat science**, v. 100, p. 156–63, fev. 2015.

QUEVEDO, R. A.; AGUILERA, J. M.; PEDRESCHI, F. Color of Salmon Fillets By Computer Vision and Sensory Panel. **Food and Bioprocess Technology**, v. 3, n. 5, p. 637–643, 26 out. 2010.

RADY, A.; ADEDEJI, A. Assessing different processed meats for adulterants using visible-near-infrared spectroscopy. **Meat Science**, v. 136, p. 59–67, 1 fev. 2018. doi: 10.1016/J.MEATSCI.2017.10.014.

RAHBARI, M.; HAMDAMI, N.; MIRZAEI, H.; JAFARI, S. M.; KASHANINEJAD, M.; KHOMEIRI, M. Effects of high voltage electric field thawing on the characteristics of chicken breast protein. **Journal of Food Engineering**, v. 216, p. 98-106, 2018.

RODRIGUEZ-GALIANO, V. F.; GHIMIRE, B.; ROGAN, J.; CHICA-OLMO, M.; RIGOL-SANCHEZ, J. P. An assessment of the effectiveness of a random forest classifier for land-cover classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 67, p. 93–104, 1 jan. 2012.

ROMANO, A.; MASI, P.; CAVELLA, S. Visual evaluation of sliced Italian salami by image analysis. **Food Science and Nutrition**, v. 6, n. 1, p. 153–159, 2018.

ROPODI, A. I.; PANAGOU, E. Z.; NYCHAS, G.-J. E. Multispectral imaging (MSI): A promising method for the detection of minced beef adulteration with horsemeat. **Food Control**, v. 73, p. 57–63, mar. 2017.

SANDORY, C., BUCHET, R., LACHENAL, G. Principles of molecular vibrations for near-infrared spectroscopy. In Ozaki, Near- infrared spectroscopy in food science and technology,

Edyted by Y., McClure, W. F., Christy, A. A. pag 11-46. 2007.

SAMS, A. R. Poultry Meat Processing. **CRC Press Taylor & Francis Group**. New York Washington, D.C. pag. 345. 2001

SARAH, S. A.; FARADALILA, W. N.; SALWANI, M. S.; AMIN, I.; KARSANI, S. A.; SAZILI, A. Q. LC-QTOF-MS identification of porcine-specific peptide in heat treated pork identifies candidate markers for meat species determination. **Food Chemistry**, v. 199, p. 157–164, 15 maio 2016.

SARCINELLI, M. F.; VENTURINI, K. S.; SILVA, L. C. DA. Características da Carne Suína. **Revista Brasileira de Zootecnia**, v. 1, n. 1, p. 1–7, 2007.

SERRANO, S.; PERÁN, F.; JIMÉNEZ-HORNERO, F. J.; DE RAVÉ, E. G. Multifractal analysis application to the characterization of fatty infiltration in Iberian and White pork sirloins. **Meat Science**, v. 93, n. 3, p. 723–732, 1 mar. 2013

SHAO, Y.; LI, Y.; JIANG, L.; PAN, J.; HE, Y.; DOU, X. Identification of pesticide varieties by detecting characteristics of *Chlorella pyrenoidosa* using Visible/Near infrared hyperspectral imaging and Raman microspectroscopy technology. **Water research**, v. 104, p. 432–440, 1 nov. 2016.

SHERLOCK, R. A.; SMITH, L. A.; MITCHELL, R. S. Automatic oestrus detection from milking data - a preliminary investigation. **Proc NZ Society for Animal Production**, v. 65, p. 228–229, 1996.

SMITH, B. C. Fundamentals of Fourier Transform Infrared Spectroscopy. Second ed. New York, USA: CRC Press Taylor & Francis Group. 2001

SONG, S. Y.; LEE, Y. K.; KIM, I.-J. Sugar and acid content of Citrus prediction modeling using FT-IR fingerprinting in combination with multivariate statistical analysis. **Food chemistry**, v. 190, p. 1027–32, 1 jan. 2016.

SOUZA D. F. Application of infrared spectroscopy and multivariate analysis to predict quality parameters in soybean and quinoa. Tesis / **Universidade Estadual de Campinas, Faculdade de Engenharia de Alimentos** pag. 119. 2013.

SU, H.; SHA, K.; HANG, L.; ZHANG, Q.; XU, Y.; ZHANG, R.; Li, H.; SUN, B. Development of near infrared reflectance spectroscopy to predict chemical composition with a wide range of variability in beef. **Meat science**, v. 98, n. 2, p. 110–4, out. 2014.

TAO, F.; PENG, Y. A method for nondestructive prediction of pork meat quality and safety attributes by hyperspectral imaging technique. **Journal of Food Engineering**, v. 126, p. 98–106, abr. 2014.

TAYLOR, J. C.; SUTTER, C.; ONTAI, L. L.; NISHINA, A.; ZIDENBERG-CHERR, S. Feasibility and reliability of digital imaging for estimating food selection and consumption from students' packed lunches. **Appetite**, v. 120, p. 196–204, 2018.

TRINDERUP, C. H.; DAHL, A.; JENSEN, K.; CARSTENSEN, J. M.; CONRADSEN, K. Comparison of a multispectral vision system and a colorimeter for the assessment of meat color. **Meat science**, v. 102, p. 1-7, April 2015.

TROY, D. J.; TIWARI, B. K.; JOO, S. T. Health Implications of Beef Intramuscular Fat Consumption. **Korean Journal for Food Science of Animal Resources**, v. 36, n. 5, p. 577–582, 2016.

USDA. Livestock and Poultry: World Markets and Trade On line: Foreign Agricultural Service 2018 (Available at [https://apps.fas.usda.gov/psdonline/circulars/livestock\\_poultry.pdf](https://apps.fas.usda.gov/psdonline/circulars/livestock_poultry.pdf) , access: 31-01-2019)

VENTURINI, K. S.; SARCINELLI, M. F.; SILVA, L. D. Características da carne de frango. **Boletim Técnico-PIE-UFES**, 1307. 2007.

VEZZANI, E. Revestimentos para carne de frango pronta para consumo. **Aliment Tecnol**, 1(8), 110-2, 1986.

VINCKE, D. et al. Analysis of collagen preservation in bones recovered in archaeological contexts using NIR Hyperspectral Imaging. **Talanta**, v. 125, p. 181–8, jul. 2014.

WANG, W.; PENG, Y.; SUN, H.; ZHENG, X.; WEI, W. Real-time inspection of pork quality attributes using dual-band spectroscopy. **Journal of Food Engineering**. Elsevier, 237, p. 103–109, 2018. doi: 10.1016/J.JFOODENG.2018.05.022.

WOLD, J. P. On-line and non-destructive measurement of core temperature in heat treated fish cakes by NIR hyperspectral imaging. **Innovative Food Science & Emerging Technologies**, v. 33, p. 431–437, fev. 2016.

WOLD, J. P.; VEISETH-KENT, E.; HØST, V.; LØVLAND, A. Rapid on-line detection and grading of wooden breast myopathy in chicken fillets by near-infrared spectroscopy. **PLOS ONE**, v. 12, n. 3, p. e0173384, 9 mar. 2017.

WOLD, J. P.; KERMIT, M.; SEGTMAN, V. H. Chemical imaging of heterogeneous muscle foods using near-infrared hyperspectral imaging in transmission mode. **Applied Spectroscopy**, v. 70, n. 6, 2016. .

XIE, A.; SUN, D. W.; XU, Z.; ZHU, Z. Rapid detection of frozen pork quality without thawing by Vis-NIR hyperspectral imaging technique. **Talanta**, v. 139, p. 208–15, 1 jul. 2015.

XIE, A.; SUN, D. W.; ZHU, Z.; PU, H. Nondestructive Measurements of Freezing Parameters of Frozen Porcine Meat by NIR Hyperspectral Imaging. **Food and Bioprocess Technology**, v. 9, n. 9, 2016.

XIONG, Z.; SUN, D. W.; PU, H.; ZHU, Z.; LUO, M. Combination of spectra and texture data of hyperspectral imaging for differentiating between free-range and broiler chicken meats. **LWT - Food Science and Technology**, v. 60, n. 2, p. 649–655, mar. 2015b.

XIONG, Z.; SUN, D. W.; XIE, A.; HAN, Z.; WANG, L. Potential of hyperspectral imaging for rapid prediction of hydroxyproline content in chicken meat. **Food chemistry**, v. 175, p. 417–422, 15 maio 2015c.

XIONG, Z.; XIE, A.; SUN, D. W.; ZENG, X. A.; LIU, D. Applications of Hyperspectral Imaging in Chicken Meat Safety and Quality Detection and Evaluation: A Review. **Critical Reviews in Food Science and Nutrition**, v. 55, n. 9, p. 1287–1301, 2015.

YANG, Q.; SUN, D.-W.; CHENG, W. Development of simplified models for nondestructive hyperspectral imaging monitoring of TVB-N contents in cured meat during drying process. **Journal of Food Engineering**, v. 192, p. 53–60, 1 jan. 2017.

YAVARI, A.; HAMED, M.; HAGHBIN, S. Retraction notice to: “VIS/NIR hyperspectroscopy technique for the measurement of moisture and fat contents of breaded-fried chicken nuggets” [Food Chem. 127 (2011) 645–650]. **Food Chemistry**, v. 138, n. 1, p. 421, maio 2013.

ZHENG, W.; FU, X.; YING, Y. Spectroscopy-based food classification with extreme learning machine. **Chemometrics and Intelligent Laboratory Systems**, v. 139, p. 42–47, 15 dez. 2014.

ZHENG, X. C.; LI, Y. Y.; PENG, Y. K.; WANG, W. X.; WANG, F.; YANG, Y. Improvement of nondestructive detection system of beef quality based on visible/near infrared spectroscopy. **Nongye Jixie Xuebao/Transactions of the Chinese Society for Agricultural Machinery**, v. 47, p. 332–339, 2016.

ZHOU, L. J.; WU, H.; LI, J. T.; WANG, Z. Y.; ZHANG, L. Y. Determination of fatty acids in broiler breast meat by near-infrared reflectance spectroscopy. **Meat science**, v. 90, n. 3, p. 658–64, mar. 2012.

ZHUANG, H.; SAVAGE, E. M. Postmortem aging and freezing and thawing storage enhance ability of early deboned chicken pectoralis major muscle to hold added salt water 1. **Poultry Science**, v. 91, n. 5, p. 1203–1209, 2012.

WILLIAMS, P.; NORRIS, K. H. Near-infrared Technology in the Agricultural and Food Industries. 2nd. ed. University of Wisconsin - Madison: American **Association of Cereal Chemists**, 2001. p. 296, 2001.

## **CAPÍTULO 3**

### **Classification of Chicken Parts Using a Portable Near-Infrared (NIR) Spectrophotometer and Machine Learning**

## **Classification of Chicken Parts Using a Portable Near-Infrared (NIR) Spectrophotometer and Machine Learning**

**Irene Marivel Nolasco Perez<sup>1</sup>, Amanda Teixeira Badaro<sup>1</sup>, Sylvio Barbon Jr<sup>2</sup>, Ana Paula AC Barbon<sup>3</sup>, Marise Aparecida Rodrigues Pollonio<sup>4</sup>, Douglas Fernandes Barbin<sup>1</sup>**

<sup>1</sup>Department of Food Engineering, University of Campinas (UNICAMP), Brazil

<sup>2</sup>Department of Computer Science, Londrina State University (UEL), Brazil

<sup>3</sup>Department of Zootechnology, Londrina State University (UEL), Brazil

<sup>4</sup>Department of Food Technology, University of Campinas (UNICAMP), Brazil

Artigo publicado no periódico *Applied Spectroscopy*,

<https://doi.org/10.1177/0003702818788878>

Received 13 Abril 2018, Accepted 13 Junio 2018,

Article first published online 31 Julho 2018, Issue published: December 1, 2018

Vol. 72(12) 1774–1780



Applied Spectroscopy  
2018, Vol. 72(12) 1774–1780  
© The Author(s) 2018  
Article reuse guidelines:  
sagepub.com/journals-permissions  
DOI: 10.1177/0003702818788878  
journals.sagepub.com/home/asp



# Classification of Chicken Parts Using a Portable Near-Infrared (NIR) Spectrophotometer and Machine Learning

Irene Marivel Nolasco Perez<sup>1</sup>, Amanda Teixeira Badaró<sup>1</sup>,  
Sylvio Barbon Jr<sup>2</sup>, Ana Paula AC Barbon<sup>3</sup>,  
Marise Aparecida Rodrigues Pollonio<sup>4</sup>, and  
Douglas Fernandes Barbin<sup>1</sup> 

## Abstract

Identification of different chicken parts using portable equipment could provide useful information for the processing industry and also for authentication purposes. Traditionally, physical–chemical analysis could deal with this task, but some disadvantages arise such as time constraints and requirements of chemicals. Recently, near-infrared (NIR) spectroscopy and machine learning (ML) techniques have been widely used to obtain a rapid, noninvasive, and precise characterization of biological samples. This study aims at classifying chicken parts (breasts, thighs, and drumstick) using portable NIR equipment combined with ML algorithms. Physical and chemical attributes (pH and L\*a\*b\* color features) and chemical composition (protein, fat, moisture, and ash) were determined for each sample. Spectral information was acquired using a portable NIR spectrophotometer within the range 900–1700 nm and principal component analysis was used as screening approach. Support vector machine and random forest algorithms were compared for chicken meat classification. Results confirmed the possibility of differentiating breast samples from thighs and drumstick with 98.8% accuracy. The results showed the potential of using a NIR portable spectrophotometer combined with a ML approach for differentiation of chicken parts in the processing industry.

## Keywords

Meat, prediction, principal component analysis, PCA, random forest, support vector machine, SVM, machine learning, near-infrared, NIR, spectroscopy

Date received: 13 April 2018; accepted: 13 June 2018

## Introduction

Nowadays, there is an increasing demand for poultry meat and poultry meat products due to their nutritional and sensorial properties, availability, and low price.<sup>1</sup> Chicken meat is considered healthier than beef because of its lower fat and cholesterol content.<sup>2</sup> In addition, unscrupulous retailers fraudulently adulterate chicken meat products for higher profit by adding water, salts, or different parts of the animal and in the processed products, replace the oil for lard.<sup>3</sup>

In this sense, concern from consumers has raised regarding the authenticity of meat products during processing, demanding analytical techniques for quality assessment, characterization, composition determination, and authentication of fresh meat and its products. Chicken meat products can be made with different parts of the carcass of the animal. For this work, it was considered of vital importance

to study three sections of the carcass—breast, thigh, and drumstick—whose composition can be decisive in the quality of the final product. Chicken breast comprises about 16–23% protein, 56–86% water, and 0.02–10% fat,<sup>4</sup> while thigh and drumstick comprise about 18–21% protein, 72–77% water, and 3–8% fat.<sup>5</sup> When chicken is processed for

<sup>1</sup>Department of Food Engineering, University of Campinas (UNICAMP), Brazil

<sup>2</sup>Department of Computer Science, Londrina State University (UEL), Brazil

<sup>3</sup>Department of Zootechnology, Londrina State University (UEL), Brazil

<sup>4</sup>Department of Food Technology, University of Campinas (UNICAMP), Brazil

## Corresponding author:

Douglas Fernandes Barbin, Department of Food Engineering, Campinas State University (UNICAMP), Campinas 13083-862, Brazil.  
Email: dfbarbin@unicamp.br

meat products, it is very difficult to differentiate the source of the meat.

Traditional analytical techniques to determine adulteration in chicken meat and its products are destructive, time-consuming, laborious, costly, and require sample preparation, besides being impractical for quality parameters detection in industrial and commercial processing lines.<sup>6,7</sup> For example, enzymatic methods and DNA-based techniques have been developed to differentiate fresh from frozen/thawed chicken meat,<sup>8,9</sup> or protein markers for discrimination of meat species in raw beef, pork, and poultry and their mixtures.<sup>10</sup> Computer vision was successfully used for online separation and classification of chicken parts including breast, leg, fillet, wing, and drumstick.<sup>11</sup> However, computer vision is based on the heterogeneity of the samples, such as differences in geometry and color. These aspects may not be very useful to differentiate ground chicken meat and to classify it according to its origin. Therefore, new analytical methods capable of classifying the origin of whole and/or minced chicken meat based on its composition must be developed.

Near-infrared (NIR) spectroscopy has been widely applied in food quality evaluation and composition determination, as well as authentication and characterization of food properties. It has also been used for continuous monitoring and quality control in the food processing industry.<sup>12–14</sup>

The use of portable spectrophotometers contributes to ease and convenient spectral data acquisition in situ with different setups through variation on the spectral range and resolution, as well as scanning time.<sup>15–17</sup> Several studies have been carried out using portable NIR spectrometer in different areas, as these instruments offer advantages such as low cost, robustness, simplicity of analysis, reduced size, and portability, allowing for online or in situ applications.<sup>16,18,19</sup>

Near-infrared spectroscopy, however, offers an immense amount of spectral data, making very difficult to extract the relevant information. In this way, the association between this technique and multivariate analysis is required for chemometric data interpretation.<sup>20</sup>

Among multivariate data analysis, there are unsupervised methods for exploratory data evaluation, such as principal component analysis (PCA), which allows identifying the directions of greater variability between the data, presenting the components graphically.

Recently, machine learning (ML) techniques have been reported for processed NIR data. Machine learning is a research field related to the automatic pattern recognition from a given knowledge database towards making decisions and predictions.<sup>21</sup> Some recent researches in the agricultural field have used NIR and ML tools with good prediction results becoming a new alternative for the traditional form of validation.<sup>22</sup>

Therefore, the present work aims at contributing in the development of a rapid and nondestructive approach to

classify different types of chicken parts, which can be potentially used in chicken products adulteration, through the use of NIR technique performed by a portable spectrophotometer associated with ML.

## Material and Methods

### Samples

The study was carried out on 137 chicken samples (52 breasts, 40 thighs, and 45 drumsticks), acquired from a local market, and 90 samples obtained by grinding the chicken parts (30 breasts, 30 thighs, and 30 drumsticks). The skin was removed from the samples.

### NIR Spectroscopy

NIR spectra were recorded from 900 to 1700 nm at 3.51 nm intervals using a portable spectrophotometer (DLN NIRscan Nano Evaluation Module (EVM), Texas Instruments, Dallas, TX) in absorbance mode. Spectral acquisitions were performed on six points of the internal side of non-minced samples and five points of the minced samples. The acquisition of the spectra was performed in the same region for all samples. Therefore, 12 spectra were collected from each of the 137 chicken samples ( $6 \times 52 + 6 \times 40 + 6 \times 45$ ) and 10 from each of 90 minced chicken samples ( $5 \times 30 + 5 \times 30 + 5 \times 30$ ).

### Physicochemical Attributes and Chemical Composition

After spectra acquisition, breast (B), thigh (T), and drumstick (D) samples were characterized following AOAC procedures,<sup>23</sup> and as reported by Murphy et al.<sup>24</sup> Dry matter was determined by oven drying at 110 °C for 24 h (AOAC, 950.46B) and the ash content was evaluated by sample incineration in a muffle at 550 °C for 4 h (AOAC, 920.153). Protein content was estimated by Kjeldahl procedure (AOAC, 928.08), using conversion factor equal to 6.25. The total lipid content was evaluated according to the modification of the method described by Bligh and Dyer,<sup>25</sup> and the results were expressed as percentage of lipids.<sup>26</sup> Sample color was measured using an Ultra Scan Vis 1043 colorimeter (Hunter Lab, Reston, VA). CIELAB L\* (lightness), a\* (redness greenness), and b\* (yellowness blueness) values were recorded from six distinct points of each sample using a D65 illuminant and 10 observer. The pH values were determined using a portable pH meter (Five Go TM F2, with sensor Inlab solids of Mettler Toledo, Switzerland) by direct contact in six points near to NIR and color measurements. The samples were analyzed in triplicate and the arithmetic mean was used as the chemical reference value of each sample. The results were evaluated by analysis of variance (ANOVA) and the Tukey test with a

significance level of 0.05, using Minitab software trial edition (Minitab 16.1.0, Minitab Inc., State College, PA).

### Data Processing and Machine Learning (ML)

Chemometric analysis was performed using Unscrambler (CAMO, Norway), Minitab, and Pirouette (Infometrix, USA). Spectra were preprocessed by applying Savitzky–Golay filter (second order, nine smoothing points), in order to smooth and reduce noise.<sup>27</sup> The pre-processing method was used on the mean spectrum extracted from each sample after mean-centering and scaling.

Classification models for chicken parts (non-minced) were developed splitting the sample set into two groups: one group was used for calibration (94 samples) and the other group was used for validation (40 samples). The same procedure was performed with the minced dataset, being 60 and 26 samples for calibration and validation, respectively. Both datasets used a division factor of 70/30.

In order to avoid overfitting, the calibration selection was made by Kennard–Stone method.<sup>28</sup> This algorithm aims at selecting a diversified sample set to be included in the training set. Basically, the distances between all pairs of samples are computed, and then the two most distant samples are included. This procedure is repeated until the desired number of samples on the training set is reached.

The calibration set was used to induce predictive models with the linear discriminant analysis (LDA), random forest (RF), and support vector machine (SVM) algorithms by a cross-validation five-fold strategy. The algorithms were selected due to their wide application, high performance, and for comparing different branches of ML. They were implemented over an R environment using the libraries MASS, randomforest, and e1071 (for LDA, RF, and SVM) with standard hyperparameters. After the RF tuning procedure, it was observed that both RF standard and RF tuned obtained identical results. On the other hand, the grid tuning procedure performed with SVM throughout kernels (linear, polynomial, and radial), gamma ( $\gamma = 0.01, 0.015, 0.020$ , and  $0.025$ ), and regularization ( $C = 0.75, 0.9, 1.0, 1.1$ , and  $1.25$ ) obtained some improvements, reported as the SVM<sup>t</sup> model. The SVM<sup>t</sup> best average accuracy was achieved when tuned to linear kernel without hyperparameter. Samples from validation set were analyzed using prediction models built from the calibration set in order to avoid any bias.

The results obtained in the classification models were represented in a confusion matrix. The confusion matrix gives some useful insights into the models capability to predict the explored classes (breast, drumstick, and thigh). Moreover, it is possible to evaluate the overall performance, accuracy, sensitivity and specificity of each model. These measures allow identification of misclassified samples and an understanding of the outcomes of each single class.<sup>29</sup>

**Table 1.** Physicochemical analysis of chicken parts.

|          | Breast                    | Thigh                     | Drumstick                 |
|----------|---------------------------|---------------------------|---------------------------|
| Moisture | 73.87 <sup>b</sup> ± 0.26 | 73.25 <sup>b</sup> ± 0.26 | 75.29 <sup>a</sup> ± 0.56 |
| Ash      | 03.59 <sup>a</sup> ± 0.59 | 03.17 <sup>a</sup> ± 0.08 | 03.26 <sup>a</sup> ± 0.13 |
| Protein  | 24.27 <sup>a</sup> ± 0.38 | 18.73 <sup>b</sup> ± 0.21 | 19.41 <sup>b</sup> ± 0.47 |
| Lipids   | 02.13 <sup>c</sup> ± 0.21 | 07.07 <sup>a</sup> ± 0.75 | 04.21 <sup>b</sup> ± 0.18 |
| pH       | 05.87 <sup>b</sup> ± 0.11 | 06.37 <sup>a</sup> ± 0.2  | 06.47 <sup>a</sup> ± 0.12 |
| L*       | 36.77 <sup>b</sup> ± 2.41 | 38.55 <sup>b</sup> ± 2.59 | 41.98 <sup>a</sup> ± 5.16 |
| a*       | −1.01 <sup>c</sup> ± 0.57 | 0.54 <sup>a</sup> ± 1.22  | −0.33 <sup>b</sup> ± 0.79 |
| b*       | 07.23 <sup>a</sup> ± 1.85 | 05.54 <sup>b</sup> ± 3.11 | 03.82 <sup>c</sup> ± 2.05 |

Means ± standard deviation. Superscript letters in the same row are significantly different as determined by Tukey test with a significance level of 0.05.

## Results and Discussion

### Physicochemical Analysis

Table 1 shows the results of physical and chemical attributes and chemical composition of the chicken parts. The range values estimated for L\*, a\*, b\*, pH, moisture, protein, lipids, ash, and fat parameters were similar to those found in the literature.<sup>30–32</sup> However, these parameters can also be related to chicken breed, age, and gender.<sup>33</sup>

The lipid content was significantly higher for thigh than for the other parts. Parameters such as pH and L\* were lower in breast than in thigh and drumstick samples, while a\* was higher in thigh than in other parts. The b\* parameter was significantly lower in drumstick and higher in breast samples. Protein content was not significantly different between thigh and drumstick samples, but a significant difference was observed among these samples and breast. The sample's moisture content showed no significant difference between breast and thigh, however, these samples were significantly different from drumstick. Finally, ash content showed no significant difference among chicken meat parts.

### Near-Infrared (NIR) Analysis

Mean NIR spectra acquired for different chicken samples, expressed as absorbance values, are illustrated in Fig. 1. Both non-minced and minced samples showed a similar trend in the whole wavelength region (900–1700 nm). However, breast samples presented higher absorbances than thighs and drumstick samples.

Peaks related to different chemical compounds present in the samples were observed, highlighting the following bands: 928 nm (3rd overtone of C–H stretch),<sup>34</sup> 1450 nm and 970 nm (first and second overtones of O–H stretching band of water).<sup>35</sup> The NIR spectra of chicken meat showed a prominent peak at the absorbance characterized by water band, due to the interactions of hydrogen bonds and other components in the meat.<sup>36</sup>




Figure 1. Raw and second derivative mean NIR spectrum of chicken meat.

### Preliminary Investigation Using Principal Component Analysis (PCA)

Spectra of chicken meat were scanned and investigated in order to find typical patterns, differences, or similarities in signal characteristics before setting up the calibration model.

The PCA (Fig. 2) of non-minced meat showed samples clusters related to the three classes (breast, drumstick, and thigh) with first and second principal components (PCs) explaining 94.4% and 4.8% of the total variance, respectively. Although drumstick and thigh showed an overlap on the PCA plot, a clear separation among these samples and breast might be observed. However, PCA of minced chicken meat was able to separate only breast from thigh and drumstick samples, with first and second PCs explaining 75.7% and 22.4% of the total variance, respectively, but thigh and drumstick showed a high overlap on the PCA plot.

Thus, ML algorithms were used in order to develop a model capable of identifying each sample by linear and non-linear relations between spectrum and classes.

### Machine Learning (ML) Classification

Classification models were based on three ML algorithms (LDA, RF, and SVM) over minced and non-minced data sets.

Table 2 shows the overall performances with the original and the projection of PCs (considering the first three components obtained with the pre-treated signal) to induce the predictive models. The induced models based on the original data obtained an average accuracy of 65.50% and 85.75% for minced and non-minced sets, respectively. The LDA model showed 73% of accuracy for minced data set, while RF showed a superior accuracy (88%) when classifying non-minced samples. On the other hand, when spectra were transformed and represented by three PCs, the classification accuracy was improved on the non-minced data set, achieving an average of 95.75%, with LDA, SVM, and SVM<sup>t</sup> reaching 97% accuracy, and reduced in minced data set, obtaining models with an average accuracy of 39.00%.

It was observed that RF algorithm dealt with noise and nonlinearities from the signal since the non-minced data set obtained a more accurate classification from this algorithm. At the same time, denoised spectra represented by PCs (linear behavior) increased the classification accuracy of LDA and SVM models.

Results obtained from validation set over non-minced samples can be analyzed through the confusion matrices exposed in Table 3. The confusion matrix for the three classes gives the predicted class as rows and original class by column. The RF algorithm achieved an overall accuracy of 90%, with sensitivities of 1.00, 0.90, and 0.84 and specificities of 0.91, 1.00, and 0.96 for drumstick, breast, and




Figure 2. PCA scores of breast, drumstick, and thigh for (a) minced and (b) non-minced samples

Table 2. Algorithm accuracy among LDA, RF, SVM, and SVM<sup>t</sup> models, comparison between minced and non-minced samples.

| Pretreatment | Algorithm        | Calibration <sup>a</sup> |            | Validation |            |
|--------------|------------------|--------------------------|------------|------------|------------|
|              |                  | Minced                   | Non-Minced | Minced     | Non-Minced |
| No           | LDA              | 63%                      | 90%        | 73%        | 85%        |
|              | RF               | 65%                      | 79%        | 62%        | 88%        |
|              | SVM              | 65%                      | 76%        | 62%        | 83%        |
|              | SVM <sup>t</sup> | 68%                      | 88%        | 65%        | 87%        |
| Yes          | LDA              | 73%                      | 79%        | 34%        | 97%        |
|              | RF               | 75%                      | 73%        | 38%        | 92%        |
|              | SVM              | 60%                      | 76%        | 42%        | 97%        |
|              | SVM <sup>t</sup> | 68%                      | 76%        | 42%        | 97%        |

<sup>a</sup> Average value after cross-validation with five folds.  
t: algorithm tuned to linear kernel.

thigh, respectively. In this way, it is possible to affirm that breast has a more distinguishable pattern from thigh and drumstick. Indeed, according to PCA results, drumstick and thigh presented overlap behavior, but showed an acceptable level of identification.

The LDA model achieved distinct results from RF, with only one misclassified sample from drumstick class. Therefore, the model obtained superior results when compared to RF regarding overall accuracy (97.5%), sensitivity (0.94, 1.00, 1.00), and specificity (1.00, 1.00, 0.96).

Lastly, SVM and SVM<sup>t</sup> models obtained a slightly similar result to LDA, misclassifying only one sample from thigh class. Consequently, superior results were found comparing to RF model in terms of overall accuracy (97.5%), sensitivity (1.00, 1.00, 0.92), and specificity (0.96, 1.00, 1.00).

Hence, a different comprehension about the samples was achieved, since the inferior specificity of thigh and drumstick led to an indication of more complex pattern to distinguish them. On the other hand, breast samples showed a more identifiable pattern.

**Table 3.** Confusion matrix of LDA, RF, SVM, and SVM<sup>t</sup> classification model of non-minced samples of validation set with pretreatment.

| Algorithm        |           | Reference |        |       |
|------------------|-----------|-----------|--------|-------|
|                  |           | Drumstick | Breast | Thigh |
| LDA              | Drumstick | 15        | 0      | 0     |
|                  | Breast    | 0         | 11     | 0     |
|                  | Thigh     | 1         | 0      | 13    |
| RF               | Drumstick | 16        | 0      | 2     |
|                  | Breast    | 0         | 10     | 0     |
|                  | Thigh     | 0         | 1      | 11    |
| SVM              | Drumstick | 16        | 0      | 1     |
|                  | Breast    | 0         | 11     | 0     |
|                  | Thigh     | 0         | 0      | 12    |
| SVM <sup>t</sup> | Drumstick | 16        | 0      | 1     |
|                  | Breast    | 0         | 11     | 0     |
|                  | Thigh     | 0         | 0      | 12    |

## Conclusion

The present research showed good results for the classification of chicken meat, where the portable NIR spectrophotometer together with chemometrics and ML algorithms allowed to discriminate the different parts of chicken by LDA, RF, and SVM. It could provide useful information for identification of chicken parts in the processing line, and also for authentication of samples in the market for processed products.

## Acknowledgments

Irene Marivel Nolasco Perez acknowledges Coordination for the Improvement of Higher Education Personnel (CAPES) for the scholarship. The authors also acknowledge the Brazilian National Council for Scientific and Technological Development (CNPq) (Grant no. 404852/2016-5).

## Conflict of Interest

The authors report there are no conflicts of interest.

## Funding

This work was supported by Sao Paulo Research Foundation (FAPESP), Young Researchers Award (grant number 2015/24351-2), and FAEPEX\_Unicamp (grant number 10316). The color meter was funded by FAPESP (grant number 2006/03263-9).

## ORCID iD

Douglas Fernandes Barbin  <http://orcid.org/0000-0001-9767-8130>

## References

1. M. Rahbari, N. Hamdami, H. Mirzaei, S.M. Jafari, et al. "Effects of High Voltage Electric Field Thawing on the Characteristics of Chicken Breast Protein". *J. Food Eng.* 2018. 216: 98–106.

2. S. Jaturasitha, T. Srikanthai, M. Kreuzer, M. Wicke. "Differences in Carcass and Meat Characteristics Between Chicken Indigenous to Northern Thailand (Black-Boned and Thai Native) and Imported Extensive Breeds (Bresse and Rhode Island Red)". *Poultry Sci.* 2008. 87(1): 160–169.
3. A.A. Aida, Y.B. Che Man, C.M.V.L. Wong, A.R. Raha, et al. "Analysis of Raw Meats and Fats of Pigs Using Polymerase Chain Reaction for Halal Authentication". *Meat Sci.* 2005. 69(1): 47–52.
4. R. Prasanna Kumar, M. Sahitya Rani. "Chemical Composition of Chicken of Various Commercial Brands Available in Market". *J. Agric. Vet. Sci.* 2014. 7(7): 22–26.
5. J. Carnevale de Almeida, M.S. Perassolo, J. Lins Camargo, N. Bragagnolo, J.L. Gross. "Fatty Acid Composition and Cholesterol Content of Beef and Chicken Meat in Southern Brazil". *Rev. Bras. Ciênc. Farm.* 2006. 42(1): 109–117.
6. J.U. Porep, D.R. Kammerer, R. Carle. "On-Line Application of Near Infrared (NIR) Spectroscopy in Food Production". *Trends Food Sci. Technol.* 2015. 46(2): 211–230.
7. M. De Marchi. "On-Line Prediction of Beef Quality Traits using Near Infrared Spectroscopy". *Meat Sci.* 2013. 94(4): 455–460.
8. P. Gottesmann, R. Hamm. "New Biochemical Methods of Differentiating Between Fresh Meat and Thawed, Frozen Meat". *Fleischwirtschaft.* 1983. 63(2): 291–221.
9. B. Bellele, P. Flori, J. Hafid, H. Raberin, et al. "Influence of the Quantity of Nonspecific DNA and Repeated Freezing and Thawing of Samples on the Quantification of Dna by the Light Cycler®". *J. Microbiol. Methods.* 2003. 55(1): 213–219.
10. G.-D. Kim, J.-K. Seo, H.-W. Yum, J.-Y. Jeong, et al. "Protein Markers for Discrimination of Meat Species in Raw Beef, Pork and Poultry and Their Mixtures". *Food Chem.* 2017. 217: 163–170.
11. N. Teimouri, M. Omid, K. Mollazadeh, H. Mousazadeh, et al. "On-Line Separation and Sorting of Chicken Portions Using a Robust Vision-Based Intelligent Modelling Approach". *Biosyst. Eng.* 2018. 167: 8–20.
12. D. Alexandrakis, G. Downey, A.G.M. Scannell. "Rapid Non-Destructive Detection of Spoilage of Intact Chicken Breast Muscle Using Near-Infrared and Fourier Transform Mid-Infrared Spectroscopy and Multivariate Statistics". *Food Bioprocess Technol.* 2012. 5(1): 338–347.
13. D. Fernandes Barbin, C.M. Kaminishikawahara, A.L. Soares, I.Y. Mizubuti, et al. "Prediction of Chicken Quality Attributes by Near Infrared Spectroscopy". *Food Chem.* 2015. 168: 554–560.
14. D. Cozzolino, I. Murray, R. Paterson, J.R. Scaife. "Visible and Near Infrared Reflectance Spectroscopy for the Determination of Moisture, Fat and Protein in Chicken Breast and Thigh Muscle". *J. Near Infrared Spectrosc.* 1996. 4(1): 213–223.
15. B. de la Roza-Delgado, A. Garrido-Varo, A. Soldado, A. González Arrojo, et al. "Matching Portable NIRS Instruments for In Situ Monitoring Indicators of Milk Composition". *Food Control.* 2017. 76: 74–81.
16. B. de la Roza-Delgado, A. Soldado, A.F. Gomes de Faria Oliveira, A. Martínez-Fernández, et al. "Assessing the Value of a Portable Near Infrared Spectroscopy Sensor for Predicting Pork Meat Quality Traits of Asturcelta Autochthonous Swine Breed". *Food Anal. Methods.* 2014. 7(1): 151–156.
17. W. Lin, Y. Peng. "A Portable Device for Rapid Nondestructive Detection of Fresh Meat Quality". *Proc. SPIE.* 2014. 9108: 91080Q.
18. M.M. Reis, K. Rosenfold. "Early On-Line Classification of Beef Carcasses Based on Ultimate pH by Near Infrared Spectroscopy". *Meat Sci.* 2014. 96(2): 862–869.
19. M. Chen, L. Zhang, H. Xu. "On-Line Detection of Blood Spot Introduced into Brown-Shell Eggs Using Visible Absorbance Spectroscopy". *Biosyst. Eng.* 2015. 131: 95–101.
20. W. Wang, J. Paliwal. "Near-Infrared Spectroscopy and Imaging in Food Quality and Safety". *Sens. Instrum. Food Qual. Saf.* 2007. 1(4): 193–207.

21. C. Liu, S.X. Yang, L. Deng. "Determination of Internal Qualities of Newhall Navel Oranges Based on NIR Spectroscopy Using Machine Learning". *J. Food Eng.* 2015. 161: 16–23.
22. A. Chemura, O. Mutanga, T. Dube. "Remote Sensing Leaf Water Stress in Coffee (*Coffea arabica*) Using Secondary Effects of Water Absorption and Random Forests". *Phys. Chem. Earth, Parts A/B/C.* 2017. 100: 317–324.
23. Association of Official Analytical Chemists (AOAC). *Official Methods of Analysis*. Arlington, VA: AOAC, 1990.
24. R.Y. Murphy, B.P. Marks. "Effect of Meat Temperature on Proteins, Texture, and Cook Loss for Ground Chicken Breast Patties". *Poultry Science*. 2000. 79(1): 99–104.
25. E.G. Bligh, W.J. Dyer. "A Rapid Method of Total Lipid Extraction and purification." *Canadian journal of biochemistry and physiology*. 1959. 37(8): 911–917.
26. C. Heliosa Máscia. *Fundamentos Teóricos e Práticos em Análise de Alimentos*. Editora da UNICAMP. 2003. 96–97.
27. A. Savitzky, M.J.E. Golay. "Smoothing and Differentiation of Data by Simplified Least Squares Procedures". *Anal. Chem.* 1964. 36(8): 1627–1639.
28. R.W. Kennard, L.A. Stone. "Computer Aided Design of Experiments". *Technometrics*. 1969. 11(1): 137–148.
29. P. Cichosz. *Data Mining Algorithms: Explained Using R*. Hoboken, NJ: John Wiley & Sons, 2014.
30. S.M. Lonergan, N. Deeb, C.A. Fedler, S.J. Lamont. "Breast Meat Quality and Composition in Unique Chicken Populations". *Poultry Sci.* 2003. 82(12): 1990–1994.
31. S. Wattanachant, S. Benjakul, D.A. Ledward. "Composition, Color, and Texture of Thai Indigenous and Broiler Chicken Muscles". *Poultry Sci.* 2004. 83(1): 123–128.
32. M. De Marchi, M. Penasa, M. Battagin, E. Zanetti, et al. "Feasibility of the Direct Application of Near-Infrared Reflectance Spectroscopy on Intact Chicken Breasts to Predict Meat Color and Physical Traits". *Poultry Sci.* 2011. 90(7): 1594–1599.
33. P. Bitencourt Faria, M.C. Bressan, X. Rodrigues de Souza, E.C. Rodrigues, et al. "Composição proximal e qualidade da carne de frangos das linhagens paraíso pedrês e pescoço pelado". *Rev. Bras. Zootec.* 2009. 38(12): 2455–2464.
34. P. Gou, E. Santos-Garcés, M. Høy, J.P. Wold, et al. "Feasibility of NIR Interactance Hyperspectral Imaging for On-Line Measurement of Crude Composition in Vacuum Packed Dry-Cured Ham Slices". *Meat Sci.* 2013. 95(2): 250–255.
35. D. Liu, J. Qu, D.-W. Sun, H. Pu, et al. "Non-Destructive Prediction of Salt Contents and Water Activity of Porcine Meat Slices by Hyperspectral Imaging in a Salting Process". *Innovative Food Sci. Emerging Technol.* 2013. 20: 316–323.
36. Y. Liu, Y.-R. Chen. "Two-Dimensional Correlation Spectroscopy Study of Visible and Near-Infrared Spectral Variations of Chicken Meats in Cold Storage". *Appl. Spectrosc.* 2000. 54(10): 1458–1470.

## **CAPÍTULO 4**

### **Comparison of rapid techniques for classification of ground meat**

### **Comparison of rapid techniques for classification of ground meat**

Irene Marivel Nolasco Pérez<sup>a</sup>, Luiz Amadeu Campedelli Moreira Rocco<sup>a</sup>, J. P. Cruz-Tirado<sup>a</sup>, Marise Rodrigues Pollonio<sup>b</sup>, Sylvio Barbon Junior.<sup>c</sup>, Ana Paula AC Barbon<sup>d</sup>, Douglas Fernandes Barbin<sup>a\*</sup>

<sup>a</sup>Department of Food Engineering, University of Campinas (UNICAMP), Brazil

<sup>b</sup>Department of Food Technology, University of Campinas (UNICAMP), Brazil

<sup>c</sup>Department of Computer Science, Londrina State University (UEL), Brazil

<sup>d</sup>Department of Zootechnology, Londrina State University (UEL), Brazil

Artigo aceito para publicação no periódico Biosystems Engineering – 2019

## Comparison of rapid techniques for classification of ground meat

Irene Marivel Nolasco Pérez<sup>a</sup>; Luiz Amadeu Campedelli Moreira Rocco<sup>a</sup> ; J. P. Cruz-Tirado<sup>a</sup>, Marise Rodrigues Pollonio<sup>b</sup>; Sylvio Barbon Junior.<sup>c</sup>; Ana Paula AC Barbon<sup>d</sup>; Douglas Fernandes Barbin<sup>a\*</sup>

<sup>a</sup>Department of Food Engineering, University of Campinas (UNICAMP), Brazil

<sup>b</sup>Department of Food Technology, University of Campinas (UNICAMP), Brazil

<sup>c</sup>Department of Computer Science, Londrina State University (UEL), Brazil

<sup>d</sup>Department of Zootechnology, Londrina State University (UEL), Brazil

\* Corresponding author: Tel.: +55 19 35210070; e-mail: dfbarbin@unicamp.br

### Abstract

Several equipment configurations are available for process control in the meat industry. Near infrared spectroscopy (NIRS) and computer vision are fast and non-invasive techniques for assessment of meat products quality and compositional parameters. This study aimed to compare a portable near-infrared (NIR) spectrometer, near infrared hyperspectral imaging (NIR-HSI) and RGB imaging (RGB-I) to identify ground meat from different species and to detect different amounts of mixture between them. Partial Least Squares regression (PLSR) models were performed using full spectra and after selecting most important wavelengths. The best results were obtained with NIR-HSI, with coefficient of prediction ( $R^2_P$ ) of 0.83 and 0.94, ratio performance to deviation (RPD) of 1.96 and 3.56, and ratio of error range (RER) of 10.0 and 18.15, for samples of chicken adulterated with pork and beef, respectively. These techniques can be used on-line by meat processing industry for processing control.

**Keywords:** authentication; food adulteration; process analytical technologies; chicken

## 1 Introduction

The poultry meat industry is increasingly growing worldwide as it is considered an important component in healthy diets. The market becomes more demanding in quality, safety, environmental legislation, ethics, and sustainable production requirements. Therefore, the quality control in the supply chain production of poultry meat is essential to assure the consumer confidence. Currently, meat and meat products adulteration with other meats or objectionable species is common practice in many countries (Ballin, Vogensen, & Karlsson, 2009). This practice can bring health risks (for instance: allergies and metabolomics disorders) (Woolfe & Primrose, 2004) and religious conflicts (Ballin, 2010).

The meat industry is dynamic and complex, needing low-cost and environmentally friendly fast techniques to ensure the quality and authenticity of products. Near Infrared Spectroscopy (NIRS) is a promising technique for food authentication because it is fast, sensitive, reagent-free and can be used for process control in the industry in continuous food processing line (Alexandrakis, Downey, & Scannell, 2012; Campos, Mussons, Antolin, Debán, & Pardo, 2017). NIRS has demonstrated to be a reliable technique for food control and food authentication in different meat products: prediction of meat quality parameters (Barbin et al., 2015; Li et al., 2016; Wang, Peng, Sun, Zheng, & Wei, 2018), meat discrimination (Prieto et al., 2015), differentiation between fresh and frozen/thawed chicken (Grunert, Stephan, Ehling-Schulz, & Johler, 2016), adulteration of turkey meat (Alamprese, Amigo, Casiraghi, & Engelsen, 2016) and beef (Rady & Adededeji, 2018), classification of chicken breast fillets (Yang et al., 2018) and classification of different parts of chicken (Nolasco Perez et al., 2018).

RGB Imaging (RGB-I) is interesting for the meat industry for its simplicity, low cost, and non-destructive nature (Santos Pereira, Barbon, Valous, & Barbin, 2018). RGB images can be captured by digital cameras, webcams or scanners from computer vision systems (CVS), that usually contains a lighting system, camera, and image analysis software using a computer (Liu, Sun, Young, Bachmeier, & Newman, 2018). This technique allows to determine the general color and visual appearance of the sample (Barbin et al., 2016). RGB-I were used to discriminate beef and pork (Arsalane, El Barbri, Rhofir, Tabyaoui, & Klilou, 2017), to predict pork color attributes (Sun, Young, Liu, & Newman, 2018), to classify and predict beef freshness (Arsalane et al., 2018).

Near infrared hyperspectral imaging (NIR-HSI) combines imaging and NIR spectroscopy, overcoming some limitations of these techniques when they are used individually. NIR-HSI provides simultaneous determination of physical and chemical properties of the sample, as well as its spatial distribution (Kandpal, Lee, Kim, Mo, & Cho, 2013). Therefore, this technology is capable of identifying analytes that are not homogeneously distributed in the food matrix (Barreto, Cruz-Tirado, Siche, & Quevedo, 2018). The capacity of NIR-HSI to identify chemical features was used for identification of beef adulterated with chicken (Kamruzzaman, Makino, & Oshita, 2016), lamb adulterated with pork (Kamruzzaman, Sun, ElMasry, & Allen, 2013) or duck meat (Zheng, Li, Wei, & Peng, 2018), beef adulterated with chicken, pork meat and/or vegetable proteins (Rady & Adediji, 2018) and adulteration of fat content in chicken meat (de Sousa Marques, Nicácio, Cidral, de Melo, & de Lima, 2013; Fernandes et al., 2019).

Each of the three techniques presents their advantages and drawbacks. NIR spectroscopy provides spectral information but several measurements are necessary, while RGB-I provides spatial information in a limited number of wavelengths. Although NIR-HSI solves this drawback by combining spatial and spectral information, it is much more expensive than NIR spectroscopy or RGB-I. In general, the meat industry can use these technologies for meat authentication and mixture routine analyzes in real time, according to their needs.

To the best of our knowledge, no work has reported identification and classification of chicken meat adulterated with pork comparing NIR-HSI, NIRS and RGB-I. Therefore, the main objective of the present study was to investigate and compare NIRS, NIR-HSI and RGB-I techniques for fast classification of pure chicken meat and chicken samples adulterated with beef and pork.

## **2 Material and methods**

### ***2.1 Sample preparation***

Meat samples from breast (chicken), leg (pork) and round (beef) were used in the present research. This study consisted of two parts: 60 samples of each type of meat (20 chicken, 20 pork, 20 beef) were prepared and used for classification models; 420 samples (210 samples adulterated with pork and 210 samples adulterated with beef) were prepared for prediction models, quantifying the amount of beef or pork added to chicken meat.

Chicken meat was mixed with pork and beef in the range of 0-50% at approximately 2%. The samples were divided in two sample sets: the training set containing 135 samples (in the range of 0-50% at approximately 2% increments) and external prediction set containing 75 samples (in the range of 0-48% at approximately 4% increments). Samples of each species were individually cut, weighed (totaling 20g) and ground together in a meat processor. The ground samples were molded in a circular glass (1.1 cm deep and 5 cm diameter).

## **2.2 NIR Spectroscopy**

NIR spectra were acquired in the range of 900 to 1700 nm at 3.51 nm intervals with 228 spectral bands using a portable spectrophotometer (NIRScan Nano, Texas Instruments, USA) in absorbance mode. The acquisition of the spectra was performed by direct contact in the same region (central part) of the sample, for all samples. Therefore, one spectrum was collected from each of the 60 pure samples and 420 adulterated samples.

## **2.3 NIR hyperspectral imaging (NIR-HSI)**

Spectral images were recorded in the range of 900 to 2500 nm, at spectral interval of 6nm with 256 spectral bands in the reflectance mode at a scanning speed of 63.30 mm/s, using a NIR-HSI system (SisuCHEMA NIR/SWIR, Specim Ltd., FIN-90571 FINLAND). The system consisted of line scan spectrograph; a near infrared spectral camera (Specim - SisuCHEMA NIR XL, SPECIM Ltd, Finland), with a line scan detector of 320 pixels and spatial resolution of 623µm; an OLE15 lens with 200mm field of view and adductor, a diffuse illumination unit of 10 W Halogen side reflector lamp Osram Ministar (Specim Ltda, Oulu, Finland), a sample tray platform, linear moving stage, and a computer supported with data acquisition software ChemaDAQ (Specim Ltda, Oulu, Finland).

Hyperspectral images were manually segmented, isolating the region of interest from each sample (ground meat) from the background, for extraction of spectral information. The segmentation was carried out to obtain the average spectrum for each sample, using the EVINCE 2.0 software (UmBio AB, 2009).

## **2.4. RGB-Imaging (RGB-I)**

Images of ground samples were captured by a computer vision system previously described (Santos Pereira, Barbon, Valous, & Barbin, 2018). The system consists of an illumination source of two LED lamps (Natural daylight, 100w- Brazil), located at an angle of 45 degrees, a digital camera (Sony, Japan) and chamber with matte black internal walls to reduce the shadowing effects. The camera settings for the images were: manual exposure with shutter speed of 1/60 s (zoom and flash off) and ISO number of 200.

#### *2.4.1 Image analysis and feature extraction*

Each color image was pre-processed in MATLAB R2016a (Mathworks, USA), the segmentation was carried out for extraction of the region of interest (ROI) by removing the background of the image. All images were separated in 3 images representing the absorption of the primary colors red, green and blue (RGB), subsequently converted to hue saturation value (HSV). Once the matrix to be analyzed was chosen, the Otsu method was used to transform the grayscale image (Mora & Fonseca, 2014; Otsu, 1979). After applying the Otsu method, a binarized image was obtained, and small objects were removed in the image to perfectly isolate the region of interest; thus, only the features of the samples were extracted. In total, 59 variables (9 variables from average of color channel R, G, B, H, S, V, L\*, a\* and b\*; 1 variable from average of binary image intensity; 28 variables from texture features of Gray Level Co-occurrence Matrix (GLCM), contrast, energy, correlation and homogeneity from R, G, B, H, V, S and binary, 21 variables from entropy, kurtosis, skewness from R, G, B, H, V, S and binary) were extracted for each image.

#### *2.5. Multivariate analyses*

Principal component analyses (PCA) was applied to the NIR spectra, NIR-HSI spectra and RGB-I data of the pure samples for classification of meat species (chicken, pork, and beef). Then, a few wavelengths were selected using the PCA loadings, and another PCA and linear discriminant analyses (LDA) were carried out using only the selected wavelengths. LDA discriminates functions to achieve maximum variation between classes and to minimize variation within each class (Pizarro, Rodríguez-Tecedor, Pérez-del-Notario, Esteban-Díez, & González-Sáiz, 2013).

Similarly, PLSR was carried out using all the wavelengths without any pre-processing technique and compared with information after MSC, SNV, 1st derivative, 2nd derivative was applied. Then, PLSR was developed in the pretreated data to verify the best result. Performance of the models were compared by root mean square error of calibration (RMSEC), cross-validation (RMSECV), and prediction (RMSEP), as well as the coefficient of determination of calibration ( $R^2_c$ ), cross-validation ( $R^2_{cv}$ ), and prediction ( $R^2_p$ ); and finally, the ratio performance to deviation (RPD) and the ratio of error range (RER).

#### *2.5.1 Selection of most relevant wavelengths*

Selecting wavelengths is important to reduce the high dimensionality of the spectral data to increase processing speed and to reduce the cost of hardware configuration (Kamruzzaman, ElMasry, Sun, & Allen, 2012). Stepwise regression (Cluff et al., 2008) and PCA loadings for the pure samples and PLSR regression coefficients for the adulterated samples were used to select important wavelengths. Stepwise regression using forward selection with p-value of 0.25 of significance level was performed to identify which variables were most relevant, using the program Minitab (Minitab 14 Inc., Release for Windows™, U.S.A.). This method begins with one wavelength and incorporates a new variable in the model at each iteration until a specified number of wavelengths is reached (Kamruzzaman & Sun, 2016; Liu, Sun, & Zeng, 2014). Regression models with selected wavelengths were used for building the adulteration map of samples.

#### *2.5.2. Adulteration map*

NIR-HSI presents the advantage of visualizing the distribution of prediction model values in the spatial domain (pixels) (Kamruzzaman, Makino, & Oshita, 2016). The PLSR model with the selected wavelengths was applied to predict the level of adulteration in each pixel of the chicken sample. The hyperspectral image at selected wavelengths was unfolded in a two-dimensional (2-D) matrix, so that each single-band image became a column vector. Each pixel in the image was multiplied by the regression coefficients obtained from the PLSR model. After multiplication, the resulting matrix was refolded to form a 2-D color image with the same dimensions of the single band image. This process results in a prediction map that demonstrates the distribution of the adulteration in each pixel of the

image. A linear color scale was used to map the predicted values of each pixel in different colors, where the colors represent different concentrations of the expected adulteration (Barbin, ElMasry, Sun, Allen, & Morsy, 2013; Kamruzzaman, Makino, & Oshita, 2016)

### 3. Results and Discussion


#### 3.1. Spectral analyses

The average NIRS spectra (900-1700 nm) in absorbance mode and NIR-HSI (900-2500 nm) in absorbance mode from chicken, beef and pork present similar trends across the NIR range 900-1700 nm (Figure 1a and Figure 1b). The characteristic bands of 970 nm and 1450 nm are related to 2<sup>nd</sup> and 1<sup>st</sup> overtone O-H stretching of water (Nolasco Perez et al., 2018; Xiong et al., 2015) and 1195 nm is related to the second overtone of CH<sub>3</sub> stretching (De Marchi, Riovanto, Penasa, & Cassandro, 2012). Specifically on the NIR-HSI spectra, the wavelength 1670 nm is related to the first overtone of the C-H stretching (Budić- Leto et al., 2011).


#### 3.2 Classification of ground meat

PCA scores were used to visualize samples with similar spectral signatures (Figures 2a, 2b and 2c). The first three principal components were responsible for 99.1% (portable NIR spectrometer), 74,0% (RGB-I), and 99.4% (NIR-HSI) of the total variance among the samples examined. Also, it is possible to observe that the samples did not overlap, showing a clear separation of the three species of ground meat. In addition, the loadings of the NIR data (Figures 3a, 3b) were used to select important wavelengths.

Figures 2d, 2e and 2f show PCA scores using selected wavelengths: 1132nm, 1261nm, 1453nm for NIR spectrometer; 1073nm, 1359nm and 1657 nm for NIR-HIS; variables mean H, mean V, mean L\* selected from RGB-I. It is possible to observe that the three classes are separate, with the first three main components responsible for 100% of the total variance among the samples examined for the three techniques, increasing its representativeness with respect to the PCA performed using all variables. Next, we performed the classification model based on the LDA algorithm using the data set of the ground meat samples.




**Figure 1.** Average spectra of ground meat samples from beef, pork and chicken acquired by: a) portable NIR spectrometer; b) NIR hyperspectral imaging system



215

216 **Figure 2.** PCA scores for ground samples of different species: (a) PCA for full spectra acquired by portable NIR spectrometer; (b) PCA for three  
 217 selected wavelengths from NIR spectrometer; (c) PCA for all features from RGB-I; (d) PCA for three selected features from RGB-I; (e) PCA for  
 218 full spectra acquired by NIR-HSI; (f) PCA for three wavelengths selected from NIR-HSI.



**Figure 3.** PCA loadings plot for ground samples of different species (a) spectra acquired by portable NIR spectrometer; (b) spectra acquired by NIR-HSI.

Results for LDA of the three classes (chicken, beef, pork) reached an overall accuracy of 100%, with sensitivity and specificity of 1.00 for the ground meat data set of the three types of species (chicken, beef and pork), for the three techniques used. The results of LDA confirmed the performance of the classification of ground meats for different species. This result corroborates previous studies carried out by Rady and Adedeji (2018) using Vis/NIR and NIR spectroscopy.

### ***3.3 Prediction of adulteration in ground chicken samples***

In this section was investigated the potential of NIR spectroscopy, NIR-HSI and RGB-I combined with PLSR to predict the concentration of pork or beef in ground chicken meat. For NIR and NIR-HSI data, the calibration models were developed using raw and pre-processed spectra (MSC, SNV, 1<sup>st</sup> derivative, 2<sup>nd</sup> derivative). Regression models using raw data provided good results to quantify beef in chicken meat using portable NIR spectrometer. However, the results for prediction of pork adulteration in chicken samples were less accurate, maybe due to the small size of the sample area analyzed in comparison to the imaging techniques (NIR-HSI or RGB-I) where the total area of the sample is assessed (Pasquini, 2018).

After applying these models to external validation set, the results of the three techniques were different from the calibration models (Table 1 and Table 2). According to De Girolamo et al., (2009)  $R^2$  values from 0.66 to 0.81 would allow the approximate quantitative prediction, while  $R^2$  between 0.82 to 0.90 would allow a good prediction and  $R^2$  higher than 0.91 would provide an excellent model. Therefore, the results shown were very good for NIR-HSI-based models to quantify pork or beef in chicken meat ( $R^2p = 0.83$  and  $R^2p = 0.94$ , respectively). For RGB-I technique ( $R^2p = 0.90$ ) the model was good for quantification of beef in chicken meat. The results for portable NIR spectrometer ( $R^2p = 0.67$ ) for quantification of beef in chicken meat were not satisfactory.

Table 1. Results for PLSR models for chicken samples adulterated with pork

| Technology     | Pre-treatment        | LV | Calibration |            |       |        | Validation |       |      |       |
|----------------|----------------------|----|-------------|------------|-------|--------|------------|-------|------|-------|
|                |                      |    | $R^2_C$     | $R^2_{CV}$ | RMSEC | RMSECV | $R^2_P$    | RMSEP | RPD  | RER   |
| <b>NIR</b>     | none                 | 5  | 0.56        | 0.38       | 13.58 | 16.20  | 0.28       | 20.32 | 0.96 | 4.92  |
|                | SNV                  | 5  | 0.48        | 0.24       | 14.66 | 17.91  | 0.02       | 23.79 | 0.82 | 4.20  |
|                | MSC                  | 5  | 0.48        | 0.24       | 14.71 | 17.95  | 0.01       | 23.90 | 0.82 | 4.18  |
|                | 1 <sup>st</sup> der. | 7  | 0.69        | 0.42       | 11,40 | 15.68  | 0.18       | 21.77 | 0.90 | 4.59  |
|                | 2 <sup>nd</sup> der. | 1  | 0.16        | 0.10       | 18.76 | 19.59  | 0.13       | 22,38 | 0.88 | 4.47  |
| <b>NIR-HSI</b> | none                 | 8  | 0.94        | 0.83       | 5.18  | 8.61   | 0.83       | 10.00 | 1.96 | 10.00 |
|                | SNV                  | 7  | 0.94        | 0.81       | 5.00  | 8.87   | 0.77       | 11.58 | 1.69 | 8,64  |
|                | MSC                  | 7  | 0.94        | 0.82       | 4.90  | 8.40   | 0.77       | 11.58 | 1.69 | 8.64  |
|                | 1 <sup>st</sup> der. | 6  | 0.91        | 0.87       | 6.16  | 7.44   | 0.80       | 10.65 | 1.84 | 9.39  |
|                | 2 <sup>nd</sup> der. | 6  | 0.90        | 0.80       | 6.32  | 9.17   | 0.84       | 9.51  | 2.66 | 10.52 |
| <b>RGB-I</b>   | none                 | 59 | 0.90        | 0.86       | 6.31  | 7.57   | 0.60       | 15.67 | 1.25 | 6.38  |

In addition, the models were evaluated based on RPD and RER in order to verify the capacity and ability of the models. RPD values in the range 1.8-2.0 indicate that the model is good, and quantitative predictions are possible; 2.0-2.5 indicate that the model is very good and larger than 2.5 indicates that model is excellent. (Kamruzzaman, Makino, & Oshita, 2016). RER values of less than 3 indicate little practical utility, RER between 3 and 10 indicate that the models are limited to good practical utility and RER greater than 10 indicate high accuracy (De Marchi et al., 2011; Jiang, Yoon, Zhuang, & Wang, 2017). The results of RPD and RER for NIR-HSI were 3.56 and 18.15 and for RGB-I were 2.56 and 13.04, respectively, indicating the models were excellent for predicting the level of beef in chicken samples.

Table 2. Results for PLSR models for chicken samples adulterated with beef

| Technique                                | Pre-treatment   | L<br>V | Calibration |             |           |            | Validation |           |         |       |
|------------------------------------------|-----------------|--------|-------------|-------------|-----------|------------|------------|-----------|---------|-------|
|                                          |                 |        | $R^2_C$     | $R^2_{C_v}$ | RMSE<br>C | RMSEC<br>V | $R^2_P$    | RMSE<br>P | RP<br>D | RER   |
| <b>Portable<br/>NIR<br/>spectrometer</b> | -               | 12     | 0.93        | 0.82        | 5.48      | 8.08       | 0.67       | 13.81     | 1.42    | 7.24  |
|                                          | SNV             | 11     | 0.92        | 0.71        | 5.92      | 11.12      | 0.59       | 15.29     | 1.28    | 6.54  |
|                                          | MSC             | 11     | 0.91        | 0.67        | 6.05      | 11.89      | 0.59       | 15.28     | 1.28    | 6.54  |
|                                          | First derivate  | 9      | 0.92        | 0.82        | 5.87      | 8.74       | 0.70       | 13.07     | 1.50    | 7.65  |
|                                          | Second derivate | 13     | 0.92        | 0.46        | 5.68      | 15.15      | 0.33       | 19.72     | 0.99    | 5.07  |
| <b>NIR-HSI</b>                           | -               | 6      | 0.98        | 0.97        | 2.82      | 3.47       | 0.94       | 5.51      | 3.56    | 18.15 |
|                                          | SNV             | 5      | 0.97        | 0.96        | 3.18      | 3.73       | 0.93       | 6.50      | 3.01    | 15.38 |
|                                          | MSC             | 5      | 0.97        | 0.96        | 3.18      | 3.76       | 0.93       | 6.50      | 3.01    | 15.38 |
|                                          | First derivate  | 5      | 0.96        | 0.95        | 2.81      | 3.09       | 0.87       | 8.27      | 2.37    | 12.09 |
|                                          | Second derivate | 5      | 0.97        | 0.95        | 2.65      | 3.7        | 0.78       | 10.71     | 1.83    | 9.34  |
| <b>RGB-I</b>                             | -               | 59     | 0.96        | 0.94        | 4.11      | 4.86       | 0.90       | 7.67      | 2.56    | 13.04 |

### 3.4 Prediction of adulteration in chicken samples using selected wavelengths

In order to improve, optimize and reduce the size and time of data processing, a few selected wavelengths and/or image features were used to develop optimized PLSR models (Table 3). The results of the validation model performed on the selected wavelengths were more accurate and robust than the models on full wavelength due to the elimination of noise and variables with redundant information. The values of the quadratic calibration and cross-calibration errors showed little difference between them, which is an indicative of good performance of the models. Coefficient of prediction ( $R^2_P$ ) was 0.66 using the portable NIR spectrometer for chicken samples adulterated with beef,

281 which indicates the possibility of using this instrument in the detection of adulterated  
282 chicken samples.

283

Table 3. Results for PLSR models with selected features for chicken samples adulterated with beef and pork

| Hyperspectral Imaging     |          |    |                          |             |            |       |        |            |       |      |       |
|---------------------------|----------|----|--------------------------|-------------|------------|-------|--------|------------|-------|------|-------|
| Samples                   |          | LV | Wavelengths              | Calibration |            |       |        | Validation |       |      |       |
|                           |          |    |                          | $R^2_C$     | $R^2_{CV}$ | RMSEC | RMSECV | $R^2_P$    | RMSEP | RPD  | RER   |
| Chicken and pork          | Loadings | 4  | 960,1054,1218, 1268,1356 | 0.87        | 0.87       | 7.20  | 7.45   | 0.84       | 9.53  | 2.54 | 10.49 |
|                           | Stepwise | 5  | 979,1048,1218,1262,1306  | 0.86        | 0.85       | 7.49  | 7.88   | 0.83       | 9.98  | 2.43 | 10.17 |
| Chicken and beef          | Loadings | 3  | 1067, 1187, 1444         | 0.95        | 0.95       | 4.05  | 4.20   | 0.92       | 6.34  | 3.82 | 15.77 |
|                           | Stepwise | 3  | 1073, 1105, 1300         | 0.96        | 0.96       | 3.61  | 3.76   | 0.91       | 6.89  | 3.51 | 14.51 |
| Portable NIR spectrometer |          |    |                          |             |            |       |        |            |       |      |       |
| Chicken and pork          | Loadings | 4  | 977,1013,1195, 1280,1476 | 0.45        | 0.41       | 15.21 | 15.93  | 0.39       | 18.68 | 1.3  | 5.35  |
|                           | Stepwise | 3  | 977,1055,1496, 1640,1682 | 0.32        | 0.27       | 17.04 | 17.55  | 0.35       | 19.42 | 1.25 | 5.15  |
| Chicken and beef          | Loadings | 4  | 1086,1195,1290,1368,1470 | 0.75        | 0.74       | 10.22 | 10.79  | 0.64       | 14.37 | 1.68 | 6.96  |
|                           | Stepwise | 5  | 977,1079,1269,1382,1406  | 0.79        | 0.78       | 9.35  | 9.80   | 0.66       | 13.99 | 1.73 | 7.15  |
| RGB Imaging               |          |    |                          |             |            |       |        |            |       |      |       |
| Chicken and pork          | SV       | 2  | GLCM G Energy            | 0.84        | 0.83       | 8.07  | 8.39   | 0.82       | 10.16 | 2.38 | 9.84  |
|                           |          |    | Average A*, Average B*,  |             |            |       |        |            |       |      |       |
| Chicken and beef          | SV       | 2  | Average G, Average BW    | 0.96        | 0.96       | 3.90  | 4.04   | 0.86       | 9.10  | 2.66 | 10.99 |
|                           |          |    | Average L*               |             |            |       |        |            |       |      |       |


284

On the other hand, for NIR-HSI and RGB-I, the values in the coefficient of prediction were  $R^2_P = 0.84$  and  $R^2_P = 0.82$  respectively, with RPD and RER values of 2.54 and 10.49, respectively, for NIR-HSI, and 2.38 and 9.84, respectively, for RGB-I. This indicates that the models were good in predicting the level of the mixtures of pork in chicken samples. For chicken meat samples adulterated with beef, RPD and RER values were 3.82 and 15.77 for NIR-HSI, respectively, and for RGB-I the RPD and RER values were 2.66 and 10.99 respectively. According to (Wold, Jakobsen, & Krane, 1996), in some cases the multivariate prediction model may improve with the selection of important variables, similar to reported in this research for NIR-HSI.

### 3.5 Prediction map

The optimized model with selected wavelengths was transferred to each pixel of the image, where the different adulteration levels from lowest to highest percentage were presented in different colors (Figure 4). As it can be observed, the hyperspectral imaging technique has the advantage of allowing the visualization of the concentration of adulteration when compared to the portable NIR technique, thus providing information about the homogeneity of the mixtures. However, the RGB-I has also provided considerable results that can be used in the meat processing industry.

**Figure 4.** Prediction map for ground chicken samples adulterated with different percentages of beef



#### 4. Conclusion

This research compared the results of three different approaches for classification of ground meat from different species and quantification of adulteration of pork and beef in ground chicken meat. Portable NIR spectrometer, NIR-HSI and RGB-I system were able to classify the ground meats with different levels of accuracy. Further, data processing was optimized with the reduction of variables, obtaining 100% classification of chicken, pork and beef samples using Linear Discriminant Analyses. PLSR models confirmed that NIR-HSI provided the best results among these techniques for quantification of beef and pork added to chicken meat, and could be a fast and non-invasive tool for meat inspection.

#### Acknowledgment

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001. Irene Marivel Nolasco Pérez acknowledges Coordination for the Improvement of Higher Education Personnel (CAPES) for the scholarship. The authors acknowledge the Brazilian National Council for Scientific and Technological Development (CNPq) (Grant no. 404852/2016-5), São Paulo Research Foundation (FAPESP), Young Researchers Award (Grant no. 2015/24351-2); FAPESP Grant no. 2008/57808-1 and 2014/50951-4; CNPq Grant no. 465768/2014-8. The authors kindly acknowledge the support provided by Mrs. Cristiane Vidal during NIR-HSI system operation and data processing.

#### 5. References

- Alamprese, C., Amigo, J. M., Casiraghi, E., & Engelsen, S. B. (2016). Identification and quantification of turkey meat adulteration in fresh, frozen-thawed and cooked ground beef by FT-NIR spectroscopy and chemometrics. *Meat Science*, 121, 175–181. <https://doi.org/10.1016/J.MEATSCI.2016.06.018>
- Alexandrakis, D., Downey, G., & Scannell, A. G. M. (2012). Rapid Non-destructive Detection of Spoilage of Intact Chicken Breast Muscle Using Near-infrared and Fourier Transform Mid-infrared Spectroscopy and Multivariate Statistics. *Food and Bioprocess Technology*, 5(1), 338–347. <https://doi.org/10.1007/s11947-009-0298-4>
- Arsalane, A., El Barbri, N., Rhofir, K., Tabyaoui, A., & Klilou, A. (2017). Beef and horse meat discrimination and storage time classification using a portable device based on DSP and PCA method. *International Journal of Intelligent Enterprise*, 4(1–2), 58–75. <https://doi.org/10.1504/IJIE.2017.087005>

- Arsalane, A., El Barbri, N., Tabyaoui, A., Klilou, A., Rhofir, K., & Halimi, A. (2018). An embedded system based on DSP platform and PCA-SVM algorithms for rapid beef meat freshness prediction and identification. *Computers and Electronics in Agriculture*, 152(July), 385–392. <https://doi.org/10.1016/j.compag.2018.07.031>
- Ballin, N. Z. (2010). Authentication of meat and meat products. *Meat Science*, 86(3), 577–587. <https://doi.org/10.1016/J.MEATSCI.2010.06.001>
- Ballin, N. Z., Vogensen, F. K., & Karlsson, A. H. (2009). Species determination – Can we detect and quantify meat adulteration? *Meat Science*, 83(2), 165–174. <https://doi.org/10.1016/J.MEATSCI.2009.06.003>
- Barbin, D. F., ElMasry, G., Sun, D.-W., Allen, P., & Morsy, N. (2013). Non-destructive assessment of microbial contamination in porcine meat using NIR hyperspectral imaging. *Innovative Food Science & Emerging Technologies*, 17, 180–191. <https://doi.org/10.1016/j.ifset.2012.11.001>
- Barbin, D. F., Kaminishikawahara, C. M., Soares, A. L., Mizubuti, I. Y., Grespan, M., Shimokomaki, M., & Hirooka, E. Y. (2015). Prediction of chicken quality attributes by near infrared spectroscopy. *Food Chemistry*, 168, 554–560. <https://doi.org/10.1016/J.FOODCHEM.2014.07.101>
- Barbin, D. F., Mastelini, S. M., Barbon, S., Campos, G. F. C., Barbon, A. P. A. C., & Shimokomaki, M. (2016). Digital image analyses as an alternative tool for chicken quality assessment. *Biosystems Engineering*, 144, 85–93. <https://doi.org/10.1016/j.biosystemseng.2016.01.015>
- Barreto, A., Cruz-Tirado, J. P., Siche, R., & Quevedo, R. (2018). Determination of starch content in adulterated fresh cheese using hyperspectral imaging. *Food Bioscience*, 21, 14–19. <https://doi.org/10.1016/J.FBIO.2017.10.009>
- Budić- Leto, I., Gajdoš, J., Zduni, G., Tomi, I., Banovi, M., Kurtanjek, Ž., & Lovri, T. (2011). Usefulness of near infrared spectroscopy and chemometrics in screening of the quality of dessert wine Prošek. *Croatian Journal of Food Science and Technology*, 3(2), 9–15.
- Campos, M. I., Mussons, M. L., Antolin, G., Debán, L., & Pardo, R. (2017). On-line prediction of sodium content in vacuum packed dry-cured ham slices by non-invasive near infrared spectroscopy. *Meat Science*, 126, 29–35. <https://doi.org/10.1016/J.MEATSCI.2016.12.005>
- Cluff, K., Naganathan, G. K., Subbiah, J., Lu, R., Calkins, C. R., & Samal, A. (2008). Optical scattering in beef steak to predict tenderness using hyperspectral imaging in the VIS-NIR

- region. *Sensing and Instrumentation for Food Quality and Safety*, 2(3), 189–196.  
<https://doi.org/10.1007/s11694-008-9052-2>
- De Girolamo, A., Lippolis, V., Nordkvist, E., & Visconti, A. (2009). Rapid and non-invasive analysis of deoxynivalenol in durum and common wheat by Fourier-Transform Near Infrared (FT-NIR) spectroscopy. *Food Additives and Contaminants - Part A Chemistry, Analysis, Control, Exposure and Risk Assessment*, 26(6), 907–917.  
<https://doi.org/10.1080/02652030902788946>
- De Marchi, M., Penasa, M., Battagin, M., Zanetti, E., Pulici, C., & Cassandro, M. (2011). Feasibility of the direct application of near-infrared reflectance spectroscopy on intact chicken breasts to predict meat color and physical traits. *Poultry Science*, 90(7).  
<https://doi.org/10.3382/ps.2010-01239>
- De Marchi, M., Riovanto, R., Penasa, M., & Cassandro, M. (2012). At-line prediction of fatty acid profile in chicken breast using near infrared reflectance spectroscopy. *Meat Science*, 90(3), 653–657. <https://doi.org/10.1016/J.MEATSCI.2011.10.009>
- de Sousa Marques, A., Nicácio, J. T. N., Cidral, T. A., de Melo, M. C. N., & de Lima, K. M. G. (2013). The use of near infrared spectroscopy and multivariate techniques to differentiate *Escherichia coli* and *Salmonella Enteritidis* inoculated into pulp juice. *Journal of Microbiological Methods*, 93(2), 90–94. <https://doi.org/10.1016/j.mimet.2013.02.003>
- Fernandes, D. D. de S., Romeo, F., Krepper, G., Di Nezio, M. S., Pistonesi, M. F., Centurión, M. E., Diniz, P. H. G. D. (2019). Quantification and identification of adulteration in the fat content of chicken hamburgers using digital images and chemometric tools. *LWT*, 100, 20–27. <https://doi.org/10.1016/J.LWT.2018.10.034>
- Grunert, T., Stephan, R., Ehling-Schulz, M., & Johler, S. (2016). Fourier Transform Infrared Spectroscopy enables rapid differentiation of fresh and frozen/thawed chicken. *Food Control*, 60, 361–364. <https://doi.org/10.1016/j.foodcont.2015.08.016>
- Jiang, H., Yoon, S.-C., Zhuang, H., & Wang, W. (2017). Predicting Color Traits of Intact Broiler Breast Fillets Using Visible and Near-Infrared Spectroscopy. *Food Analytical Methods*, 10(10), 3443–3451. <https://doi.org/10.1007/s12161-017-0907-1>
- Kamruzzaman, M., ElMasry, G., Sun, D.-W., & Allen, P. (2012). Prediction of some quality attributes of lamb meat using near-infrared hyperspectral imaging and multivariate analysis. *Analytica Chimica Acta*, 714, 57–67.  
<https://doi.org/10.1016/J.ACA.2011.11.037>
- Kamruzzaman, M., Makino, Y., & Oshita, S. (2016). Rapid and non-destructive detection of

- chicken adulteration in ground beef using visible near-infrared hyperspectral imaging and machine learning. *Journal of Food Engineering*, 170, 8–15. <https://doi.org/10.1016/J.JFOODENG.2015.08.023>
- Kamruzzaman, M., & Sun, D.-W. (2016). Introduction to Hyperspectral Imaging Technology. In *Computer Vision Technology for Food Quality Evaluation* (pp. 111–139). Elsevier. <https://doi.org/10.1016/B978-0-12-802232-0.00005-0>
- Kamruzzaman, M., Sun, D.-W., ElMasry, G., & Allen, P. (2013). Fast detection and visualization of ground lamb meat adulteration using NIR hyperspectral imaging and multivariate image analysis. *Talanta*, 103. <https://doi.org/10.1016/j.talanta.2012.10.020>
- Kandpal, L. M., Lee, H., Kim, M. S., Mo, C., & Cho, B.-K. (2013). Hyperspectral reflectance imaging technique for visualization of moisture distribution in cooked chicken breast. *Sensors (Basel, Switzerland)*, 13(10). <https://doi.org/10.3390/s131013289>
- Li, X., Feng, F., Gao, R., Wang, L., Qian, Y., Li, C., & Zhou, G. (2016). Application of near infrared reflectance (NIR) spectroscopy to identify potential PSE meat. *Journal of the Science of Food and Agriculture*, 96(9). <https://doi.org/10.1002/jsfa.7493>
- Liu, D., Sun, D.-W., & Zeng, X.-A. (2014). Recent Advances in Wavelength Selection Techniques for Hyperspectral Image Processing in the Food Industry. *Food and Bioprocess Technology*, 7(2), 307–323. <https://doi.org/10.1007/s11947-013-1193-6>
- Liu, J.-H., Sun, X., Young, J. M., Bachmeier, L. A., & Newman, D. J. (2018). Predicting pork loin intramuscular fat using computer vision system. *Meat Science*, 143, 18–23. <https://doi.org/10.1016/J.MEATSCI.2018.03.020>
- Mora, A. D., & Fonseca, J. M. (2014). Metodologia para a detecção de artefactos luminosos em imagens de retinografia com aplicação em rastreio oftalmológico. *RISTI - Revista Iberica de Sistemas E Tecnologias de Informacao*, (13), 51–63. <https://doi.org/10.4304/risti.13.51-63>
- Nolasco Perez, I. M., Badaró, A. T., Barbon, S., Barbon, A. P. A., Pollonio, M. A. R., & Barbin, D. F. (2018). Classification of Chicken Parts Using a Portable Near-Infrared (NIR) Spectrophotometer and Machine Learning. *Applied Spectroscopy*, 0(0), 370281878887. <https://doi.org/10.1177/0003702818788878>
- Otsu, N. (1979). A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62–66. <https://doi.org/10.1109/TSMC.1979.4310076>
- Pasquini, C. (2018). Near infrared spectroscopy: A mature analytical technique with new

- perspectives – A review. *Analytica Chimica Acta*, 1026, 8–36.  
<https://doi.org/10.1016/J.ACA.2018.04.004>
- Pizarro, C., Rodríguez-Tecedor, S., Pérez-del-Notario, N., Esteban-Díez, I., & González-Sáiz, J. M. (2013). Classification of Spanish extra virgin olive oils by data fusion of visible spectroscopic fingerprints and chemical descriptors. *Food Chemistry*, 138(2–3), 915–922.  
<https://doi.org/10.1016/J.FOODCHEM.2012.11.087>
- Prieto, N., Juárez, M., Larsen, I. L., López-Campos, Ó., Zijlstra, R. T., & Aalhus, J. L. (2015). Rapid discrimination of enhanced quality pork by visible and near infrared spectroscopy. *Meat Science*, 110. <https://doi.org/10.1016/j.meatsci.2015.07.006>
- Rady, A., & Adedeji, A. (2018). Assessing different processed meats for adulterants using visible-near-infrared spectroscopy. *Meat Science*, 136, 59–67.  
<https://doi.org/10.1016/J.MEATSCI.2017.10.014>
- Santos Pereira, L. F., Barbon, S., Valous, N. A., & Barbin, D. F. (2018). Predicting the ripening of papaya fruit with digital imaging and random forests. *Computers and Electronics in Agriculture*, 145, 76–82. <https://doi.org/10.1016/J.COMPAG.2017.12.029>
- Sun, X., Young, J., Liu, J.-H., & Newman, D. (2018). Prediction of pork loin quality using online computer vision system and artificial intelligence model. *Meat Science*, 140, 72–77. <https://doi.org/10.1016/J.MEATSCI.2018.03.005>
- Wang, W., Peng, Y., Sun, H., Zheng, X., & Wei, W. (2018). Real-time inspection of pork quality attributes using dual-band spectroscopy. *Journal of Food Engineering*, 237, 103–109. <https://doi.org/10.1016/J.JFOODENG.2018.05.022>
- Wold, J. P., Jakobsen, T., & Krane, L. (1996). Atlantic Salmon Average Fat Content Estimated by Near-Infrared Transmittance Spectroscopy. *Journal of Food Science*, 61(1), 74–77.
- Woolfe, M., & Primrose, S. (2004). Food forensics: using DNA technology to combat misdescription and fraud. *Trends in Biotechnology*, 22(5), 222–226.  
<https://doi.org/10.1016/J.TIBTECH.2004.03.010>
- Xiong, Z., Sun, D.-W., Xie, A., Pu, H., Han, Z., & Luo, M. (2015). Quantitative determination of total pigments in red meats using hyperspectral imaging and multivariate analysis. *Food Chemistry*, 178, 339–345. <https://doi.org/10.1016/j.foodchem.2015.01.071>
- Yang, Y., Zhuang, H., Yoon, S.-C., Wang, W., Jiang, H., & Jia, B. (2018). Rapid classification of intact chicken breast fillets by predicting principal component score of quality traits with visible/near-Infrared spectroscopy. *Food Chemistry*, 244, 184–189.  
<https://doi.org/10.1016/J.FOODCHEM.2017.09.148>

471 Zheng, X., Li, Y., Wei, W., & Peng, Y. (2018). Detection of adulteration with duck meat in  
472 ground lamb meat by using visible near-infrared hyperspectral imaging. *Meat Science*.  
473 <https://doi.org/10.1016/J.MEATSCI.2018.11.005>  
474

# **CAPÍTULO 5**

## **Discussão geral**

## 5. DISCUSSÃO GERAL

De forma geral, as técnicas de espectroscopia NIR, imagem RGB e imagem hiperespectral, utilizadas neste estudo para classificação e quantificação de amostras de carnes, provaram ser eficientes. Os objetivos do trabalho variaram desde a identificação de partes (cortes) de frangos frescos e moídos até a identificação de amostras de diferentes espécies (bovino, suíno, frangos), passando pela mistura de diferentes quantidades entre estas, em amostras moídas.

O espectrômetro portátil demonstrou resultados positivos para classificação de diferentes partes da carcaça de frango. A diferença na composição química majoritária entre estas partes, conforme apresentado no artigo 1, permite inferir que o sucesso obtido com a utilização do equipamento esteja ligado a variação de componentes entre estas partes, uma vez que o espectro no intervalo NIR é afetado por ligações de compostos orgânicos.

O mesmo pode também ser o fator para o sucesso da técnica de imagem hiperespectral para a classificação de amostras de diferentes espécies (Artigo 2). Entretanto, neste trabalho, fica evidenciada a desvantagem do espectrômetro portátil em relação a NIR-HSI, uma vez que a pequena área amostrada pelo espectrômetro pode ter levado aos baixos valores de classificação dos modelos obtidos.

Neste trabalho também ficou evidenciada a vantagem de NIR-HSI de apresentar o mapa químico das amostras, com a aplicação do modelo de regressão obtido, para quantificar o componente alvo de forma espacial na amostra. Comparado ao sistema de imagem RGB tradicional, o método NIR-HSI apresentou a vantagem da utilização da informação espectral, para detecção da composição química da amostra.

Todas as técnicas estudadas representam alternativas para avaliação do processamento de produtos derivados da carne para autenticação e assim garantir ao consumidor um produto de qualidade, evitando problemas de saúde e questões religiosas, por pessoas que não podem ingerir determinado tipo de carne. Estas técnicas podem ser utilizadas pela indústria em produtos processados, para controle de processos ou avaliação de produtos acabados.

# **CAPÍTULO 6**

## **Conclusão geral**

## 6. CONCLUSÃO GERAL

As amostras de carnes de frango foram avaliadas, tanto quanto a diferença entre diferentes cortes do animal, como em relação a diferença com outras espécies (suíno e bovino), conforme proposto no objetivo geral desta tese.

O equipamento portátil de espectroscopia no infravermelho próximo apresentou bons resultados na detecção de diferentes cortes de amostras de frango (peito, coxa e sobrecoxa), podendo ser uma alternativa na indústria de processamento e como ferramenta de inspeção de produtos processados. Por ser um método óptico não-invasivo, e relativamente de baixo custo, poder ser implementado em unidades de processamento de frango para inspeção rápida de cortes de frango.

No segundo estudo foi realizada a comparação entre as técnicas de espectroscopia no infravermelho próximo (espectrômetro *NIR* portátil e imagem hiperespectral) e imagens *RGB* para identificação das amostras de carnes de diferentes espécies, bem como determinar a quantidade de misturas de amostras moídas de carne bovina e suína em frango. Os resultados demonstraram que *NIR-HSI* foi o método mais preciso para identificação e também quantificação de misturas entre amostras moídas de diferentes espécies. As vantagens de combinar informação espacial das amostras na forma de imagens com informação espectral no intervalo *NIR* foram proporcionaram modelos de classificação e predição mais precisos que os equipamentos de imagens *RGB* e espectrômetro *NIR* portátil. Estes últimos, apesar de não fornecerem resultados tão precisos quanto *NIR-HSI*, proporcionaram modelos satisfatórios de classificação e predição, podendo ser utilizados como ferramentas úteis para estas tarefas.

A comparação entre os dois métodos de seleção de comprimento de onda mostrou que tanto os coeficientes de regressão do PLSR quanto Stepwise forneceram bons resultados para a predição de misturas de amostras de carnes de diferentes espécies, comparando as três técnicas utilizadas (espectroscopia *NIR* portátil, *RGB-I* e *NIR-HSI*). Ao desenvolver o modelo utilizando menor quantidade de comprimentos de onda, os modelos tiveram bons resultados, possibilitando a utilização de poucos comprimentos de onda para desenvolvimento de equipamentos multispectrais de menor custo.

# **CAPÍTULO 7**

## **Referências Bibliográficas**

- ADELINE, K. R. M.; GOMEZ, C.; GORRETTA, N.; ROGER, J. M. Predictive ability of soil properties to spectral degradation from laboratory Vis-NIR spectroscopy data. **Geoderma**, v. 288, p. 143-153, 2017.
- ALEXANDRAKIS, D., DOWNEY, G. AND SCANNELL, A. G. M. Rapid Non-destructive Detection of Spoilage of Intact Chicken Breast Muscle Using Near-infrared and Fourier Transform Mid-infrared Spectroscopy and Multivariate Statistics, **Food and Bioprocess Technology**, 5(1), pp. 338–347. doi: 10.1007/s11947-009-0298-4. 2012.
- ALAMPRESE, C.; FONGARO, L.; CASIRAGHI, E. Effect of fresh pork meat conditioning on quality characteristics of salami. **Meat Science**, v. 119, p. 193-198, 1 set. 2016.
- ALMEIDA, J. C. D.; PERASSOLO, M. S.; CAMARGO, J. L.; BRAGAGNOLO, N.; GROSS, J. L. Fatty acid composition and cholesterol content of beef and chicken meat in Southern Brazil. **Revista Brasileira de Ciências Farmacêuticas**, v. 42, n. 1, p. 109-117, 2006.
- ARIANA, D. P.; LU, R.; GUYER, D. E. Near-infrared hyperspectral reflectance imaging for detection of bruises on pickling cucumbers. **Computers and Electronics in Agriculture**, v. 53, n. 1, p. 60-70, 1 ago. 2006.
- ARSALANE, A.; BARBRI, N. E.; RHOFIR, K.; TABYAOUI, A.; & KLILOU, A. Beef and horse meat discrimination and storage time classification using a portable device based on DSP and PCA method. **International Journal of Intelligent Enterprise**, v. 4, n. 1-2, p. 58–75, doi: 10.1504/IJIE.2017.087005. 2017.
- ARSALANE, A.; EL BARBRI, N.; TABYAOUI, A.; KLILOU, A.; RHOFIR, K.; HALIMI, A. 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, n. July, p. 385-392. 2018
- ASSOCIATION OF OFFICIAL ANALYTICAL CHEMISTS (AOAC). Official Methods of Analysis. Arlington, VA: AOAC, 1990
- AZEVEDO, E. CONCI; GRÁFICA, A. **Computação. Teoria e Prática.**—Ed. 2003.
- BALAGE, J. M.; E SILVA, S. D. L.; GOMIDE, C. A., DE NADAI BONIN, M.; & FIGUEIRA, A. C. Predicting pork quality using Vis/NIR spectroscopy. **Meat science**, v. 108, p. 37-43, out. 2015.
- BALLIN, N. Z. Authentication of meat and meat products', **Meat Science**. Elsevier, 86(3), pp. 577–587. doi: 10.1016/J.MEATSCI.2010.06.001. 2010
- BARAKAT, H.; EL-GARHY, H. A. S.; MOUSTAFA, M. M. A. Detection of pork adulteration in processed meat by species-specific PCR-QIAxcel procedure based on D-loop and cytb genes. **Applied Microbiology and Biotechnology**, v. 98, n. 23, p. 9805–9816, 17 dez. 2014.
- BARBIN, D. F.; ELMASRY, G.; SUN, D. W.; ALLEN, P. Non-destructive determination of chemical composition in intact and minced pork using near-infrared hyperspectral imaging. **Food Chemistry**, v. 138, n. 2–3, p. 1162-1171, 1 jun. 2013.

- BARBIN, D.; ELMASRY, G.; SUN, D. W.; ALLEN, P. Near-infrared hyperspectral imaging for grading and classification of pork. **Meat Science**, v. 90, n. 1, p. 259-268, 1 jan. 2012.
- BARBIN, D. F.; KAMINISHIKAWAHARA, C. M.; SOARES, A. L.; MIZUBUTI, I. Y.; GRESPAN, M.; SHIMOKOMAKI, M.; HIROOKA, E. Y. Prediction of chicken quality attributes by near infrared spectroscopy. **Food Chemistry**, v. 168, p. 554-560, 1 fev. 2015.
- BARBIN, D. F.; MASTELINI, S. M.; BARBON JR, S.; CAMPOS, G. F.; BARBON, A. P. A.; SHIMOKOMAKI, M. Digital image analyses as an alternative tool for chicken quality assessment. **Biosystems Engineering**, v. 144, p. 85–93, 2016.
- BARBON, A. P. A.; BARBON JR, S.; MANTOVANI, R. G.; FUZYI, E. M.; PERES, L. M.; BRIDI, A. M. Storage time prediction of pork by Computational Intelligence. **Computers and Electronics in Agriculture**, v. 127, p. 368–375, 2016.
- BARBON, A. P. A.; BARBON JR, S.; CAMPOS, G. F. C.; SEIXAS JR, J. L.; PERES, L. M.; MASTELINI, S. M.; Andreo, N; ULRICI A.; BRIDI, A. M. Development of a flexible Computer Vision System for marbling classification. **Computers and Electronics in Agriculture**, v. 142, p. 536–544, 1 nov. 2017.
- BARBUT, S. Poultry products processing an industry guide. Editorial **CRC Press**, p. 173-178. 2002.
- BEEBE, K. R.; PELL, R. J.; SEASHOLTZ, M. B. Chemometrics: A practical guide. New York: Wiley. 1998.
- BEEBE, K. R.; KOWALSKI, B. R. An introduction to multivariate calibration and analysis. **Analytical Chemistry**, 59(17), 1007A-1017A. 1987.
- BELLETE, B.; FLORI, P.; HAFID, J.; RABERIN, H.; SUNG, R. T. M. Influence of the quantity of nonspecific DNA and repeated freezing and thawing of samples on the quantification of DNA by the Light Cycler®. **Journal of microbiological methods**, v. 55, n. 1, p. 213-219, 2003.
- BERZAGHI, P.; DALLE ZOTTE, A.; JANSSON, L. M.; ANDRIGHETTO, I. Near-infrared reflectance spectroscopy as a method to predict chemical composition of breast meat and discriminate between different n-3 feeding sources. **Poultry Science**, v. 84, n. 1, p. 128–136, 2005.
- BILGE, G.; VELIOGLU, H. M.; SEZER, B.; ESELLER, K. E.; BOYACI, I. H. Identification of meat species by using laser-induced breakdown spectroscopy. **Meat science**, 119, 118-122. 2016.
- BLIGH, E. G.; DYER, W. J. A rapid method of total lipid extraction and purification. **Canadian journal of biochemistry and physiology**, v. 37, n. 8, p. 911-917, 1959.
- BOWKER, B.; HAWKINS, S.; ZHUANG, H. Measurement of water-holding capacity in raw and freeze-dried broiler breast meat with visible and near-infrared spectroscopy. **Poultry Science**, v. 93, n. 7, p. 1834–1841, 2014.

BRANDELLI, A.; SALA, L.; KALIL, S. J. Microbial enzymes for bioconversion of poultry waste into added-value products. **Food Research International**, v. 73, p. 3–12, 1 jul. 2015.

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

BUDIC-LETO, I.; GAJDOŠ-KLUSURIC, J.; ZDUNIC, G. Usefulness of near infrared spectroscopy and chemometrics in screening of the quality of dessert wine Prošek, **Croatian journal of food science and technology**, 3(2), pp. 9–15.2011

CAMPOS, M. I.; MUSSONS, M. L.; ANTOLIN, G.; DEBÁN, L.; PARDO, R. On-line prediction of sodium content in vacuum packed dry-cured ham slices by non-invasive near infrared spectroscopy. **Meat science**, 126, 29-35. 2017 doi: 10.1016/J.MEATSCI.2016.12.005.

CECCHI, Heloisa Máscia. Fundamentos teóricos e práticos em análise de alimentos. - Campinas. **SP: editora da Unicamp**, 2003.

CEN, H.; LU, R.; ZHU, Q.; MENDOZA, F. Nondestructive detection of chilling injury in cucumber fruit using hyperspectral imaging with feature selection and supervised classification. **Postharvest Biology and Technology**, v. 111, p. 352-361, jan. 2016.

CHANAMAI, R.; MCCLEMENTS, D. J. Ultrasonic determination of chicken composition. **Journal of Agricultural and Food Chemistry**, v. 47, n. 11, 1999.

CHELLADURAI, V.; KARUPPIAH, K., JAYAS, D. S.; FIELDS, P. G.; WHITE, N. D. G. Detection of *Callosobruchus maculatus* (F.) infestation in soybean using soft X-ray and NIR hyperspectral imaging techniques. **Journal of Stored Products Research**, v. 57, p. 43–48, abr. 2014.

CHEMURA, A.; MUTANGA, O.; DUBE, T. Remote sensing leaf water stress in coffee (*Coffea arabica*) using secondary effects of water absorption and random forests. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 100, p. 317-324, 1 ago. 2017.

CHEN, M.; ZHANG, L.; XU, H. On-line detection of blood spot introduced into brown-shell eggs using visible absorbance spectroscopy. **Biosystems Engineering**, v. 131, p. 95-101, 2015.

CHENG, J. H.; CHOU, H. T.; LEE, M. S.; SHEU, S. C. Development of qualitative and quantitative PCR analysis for meat adulteration from RNA samples. **Food Chemistry**, v. 192, p. 336–342, 1 fev. 2016.

CHENG, J.-H.; NICOLAI, B.; SUN, D.-W. Hyperspectral imaging with multivariate analysis for technological parameters prediction and classification of muscle foods: A review. **Meat Science**, v. 123, p. 182–191, 1 jan. 2017.

CHENG, J.-H.; SUN, D.-W. Rapid and non-invasive detection of fish microbial spoilage by visible and near infrared hyperspectral imaging and multivariate analysis. **LWT - Food Science and Technology**, v. 62, n. 2, p. 1060-1068, 1 jul. 2015a.

CHENG, J.-H.; SUN, D.-W. Hyperspectral imaging as an effective tool for quality analysis and control of fish and other seafoods: Current research and potential applications. **Trends in Food Science & Technology**, v. 37, n. 2, p. 78–91, 1 jun. 2014.

CHENG, J.-H.; SUN, D.-W. Data fusion and hyperspectral imaging in tandem with least squares-support vector machine for prediction of sensory quality index scores of fish fillet. **LWT - Food Science and Technology**, v. 63, n. 2, p. 892–898, out. 2015b.

CHENG, J. H.; SUN, D. W.; PU, H. B.; CHEN, X.; LIU, Y.; ZHANG, H.; LI, J. L. Integration of classifiers analysis and hyperspectral imaging for rapid discrimination of fresh from cold-stored and frozen-thawed fish fillets. **Journal of Food Engineering**, v. 161, p. 33-39, 1 set. 2015.

CHIESA, L. et al. Authentication of Italian PDO lard using NIR spectroscopy, volatile profile and fatty acid composition combined with chemometrics. **Food Chemistry**, v. 212, 2016.

CICHOSZ, P. **Data mining algorithms: explained using R**. John Wiley & Sons, 2014.

CLUFF, K.; NAGANATHAN, G. K.; SUBBIAH, J.; LU, R.; CALKINS, C. R.; SAMAL, A. Optical scattering in beef steak to predict tenderness using hyperspectral imaging in the VIS-NIR region. **Sensing and Instrumentation for Food Quality and Safety**, 2(3), 189-196. 2008.

COZZOLINO, D.; MURRAY, I.; PATERSON, R.; SCAIFE, J. R. Visible and near infrared reflectance spectroscopy for the determination of moisture, fat and protein in chicken breast and thigh muscle. **Journal of Near Infrared Spectroscopy**, v. 4, n. 1, p. 213-223, 1996.

COZZOLINO, D.; VADELL, A.; BALLESTEROS, F.; GALIETTA, G.; BARLOCCO, N. Combining visible and near-infrared spectroscopy with chemometrics to trace muscles from an autochthonous breed of pig produced in Uruguay: A feasibility study. **Analytical and Bioanalytical Chemistry**, v. 385, n. 5, p. 931-936, 2006.

DAI, Q.; CHENG, J. H.; SUN, D. W.; ZHU, Z.; ; PU, H. Prediction of total volatile basic nitrogen contents using wavelet features from visible/near-infrared hyperspectral images of prawn (*Metapenaeus ensis*). **Food Chemistry**, v. 197, n. Pt A, p. 257–65, 15 abr. 2016.

DALE, L. M.; THEWIS, A.; BOUDRY, C.; ROTAR, I.; DARDENNE, P.; BAETEN, V.; ; PIERNA, J. A. F. Hyperspectral Imaging Applications in Agriculture and Agro-Food Product Quality and Safety Control: A Review. **Applied Spectroscopy Reviews**, v. 48, n. 2, p. 142–159, 2013.

DALLA COSTA, F. A.; DE CASTRO TAVERNARI, F.; DALLA COSTA, O. A.; DE CASTRO, F. F.; REMUS, A. Enriquecimento com ácidos graxos da série ômega 3 em carne de aves e ovos. **Pubvet**, v. 11, p. 103-206. 2016.

DE GIROLAMO, A.; LIPPOLIS, V.; NORDKVIST, E.; VISCONTI, A. Rapid and non-invasive analysis of deoxynivalenol in durum and common wheat by Fourier-Transform Near Infrared (FT-NIR) spectroscopy, **Food Additives and Contaminants - Part A Chemistry, Analysis, Control, Exposure and Risk Assessment**, 26(6), pp. 907–917. doi: 10.1080/02652030902788946. 2009.

DE LA ROZA-DELGADO, B.; GARRIDO-VARO, A.; SOLDADO, A.; ARROJO, A. G.; VALDÉS, M. C.; MAROTO, F.; PÉREZ-MARÍN, D. Matching portable NIRS instruments for in situ monitoring indicators of milk composition. **Food Control**, v. 76, p. 74-81, 2017.

DE LA ROZA-DELGADO, B.; SOLDADO, A.; DE FARIA OLIVEIRA, A. F. G.; MARTÍNEZ-FERNÁNDEZ, A.; ARGAMENTERÍA, A. Assessing the value of a portable near infrared spectroscopy sensor for predicting pork meat quality traits of “Asturcelta autochthonous swine breed”. **Food Analytical Methods**, v. 7, n. 1, p. 151-156, 2014.

DE MARCHI, M. On-line prediction of beef quality traits using near infrared spectroscopy. **Meat Science**, v. 94, n. 4, p. 455-460, 2013.

DE MARCHI, M.; PENASA, M.; BATTAGIN, M.; ZANETTI, E., PULICI, C.; CASSANDRO, M. Feasibility of the direct application of near-infrared reflectance spectroscopy on intact chicken breasts to predict meat color and physical traits. **Poultry science**, v. 90, n. 7, p. 1594-1599, 2011.

DE MARCHI, M.; PENASA, M.; BATTAGIN, M.; ZANETTI, E.; PULICI, C.; CASSANDRO, M. Feasibility of the direct application of near-infrared reflectance spectroscopy on intact chicken breasts to predict meat color and physical traits. **Poultry science**, 90(7), 1594-1599. 2011.

DE MARCHI, M.; RIOVANTO, R.; PENASA, M.; CASSANDRO, M. At-line prediction of fatty acid profile in chicken breast using near infrared reflectance spectroscopy. **Meat science**, 90(3), 653-657. 2012.

DE OLIVEIRA, G. Abatedouro de Aves - Brasil Foods SAA Universidade Tecnológica. Estágio Supervisionado. **Federal do Paraná Campus – Campo Mourão Coordenação de Engenharia de Alimentos**. 19 pag.2014

ELLIS, D. I.; BROADHURST, D.; GOODACRE, R. Rapid and quantitative detection of the microbial spoilage of beef by Fourier transform infrared spectroscopy and machine learning. **Analytica Chimica Acta**, v. 514, n. 2, p. 193–201, 1 jul. 2004.

ELMASRY, G.; BARBIN, D. F.; SUN, D. W.; ALLEN, P. Meat Quality Evaluation by Hyperspectral Imaging Technique: An Overview. **Critical Reviews in Food Science and Nutrition**, v. 52, n. 8, p. 689-711, 2012.

ELMASRY, G.; IQBAL, A.; SUN, D. W.; ALLEN, P., ; WARD, P. Quality classification of cooked , sliced turkey hams using NIR hyperspectral imaging system. **Journal of Food Engineering**, v. 103, n. 3, p. 333-344, 2011.

ELMASRY, G.; SUN, D.-W.; ALLEN, P. Near-infrared hyperspectral imaging for predicting colour, pH and tenderness of fresh beef. **Journal of Food Engineering**, v. 110, n. 1, p. 127-140, maio 2012.

ELMASRY, G.; SUN, D.-W.; ALLEN, P. Chemical-free assessment and mapping of major constituents in beef using hyperspectral imaging. **Journal of Food Engineering**, v. 117, n. 2, p. 235-246, jul. 2013.

FARIA, P. B.; BRESSAN, M. C., SOUZA, X. R.; RODRIGUES, E. C.; CARDOSO, G. P.; GAMA, L. T. Composição proximal e qualidade da carne de frangos das linhagens Paraíso Pedrês e Pescoço Pelado. **Revista Brasileira de Zootecnia**, v. 38, n. 12, p. 2455-2464, 2009.

FATHI, M.; MOHEBBI, M.; RAZAVI, S. M. A. Application of Image Analysis and Artificial Neural Network to Predict Mass Transfer Kinetics and Color Changes of Osmotically Dehydrated Kiwifruit. **Food and Bioprocess Technology**, v. 4, n. 8, p. 1357–1366, 2011.

FENG, Y.-Z.; SUN, D.-W. Determination of total viable count (TVC) in chicken breast fillets by near-infrared hyperspectral imaging and spectroscopic transforms. **Talanta**, v. 105, p. 244–249, 15 fev. 2013.

FENG, Y. Z.; ELMASRY, G.; SUN, D. W.; SCANNELL, A. G.; WALSH, D.; MORCY, N. Near-infrared hyperspectral imaging and partial least squares regression for rapid and reagentless determination of Enterobacteriaceae on chicken fillets. **Food chemistry**, v. 138, n. 2-3, p. 1829–36, 1 jun. 2013.

FERNANDES, D. D. DE S.; ROMEO, F.; KREPPER, G.; DI NEZIO, M. S.; PISTONESI, M. F.; CENTURIÓN, M. E.; DE ARAUJO, M. C. U.; DINIZ, P. H. G. D. Quantification and identification of adulteration in the fat content of chicken hamburgers using digital images and chemometric tools. **LWT**, 100, 20-27. 2019

FERREIRA, Marcia Miguel Castro. Quimiometria: conceitos, métodos e aplicações. **Campinas, SP: Editora da Unicamp**, v. 496, 2015.

FONGARO, L.; ALAMPRESE, C.; CASIRAGHI, E. Ripening of salami: assessment of colour and aspect evolution using image analysis and multivariate image analysis. **Meat science**, v. 101, p. 73–7, mar. 2015.

GELADI, P.; KOWALSKI, B. R. Partial least-squares regression: a tutorial. **Analytica Chimica Acta**, v. 185, p. 1–17, 1 jan. 1986.

GEMPERLINE, P. J. Principal component analysis PCA. In: GEMPERLINE, P. J. (Ed.). Practical Guide to Chemometrics. Second ed. [S.l.] CRC Press, p. 69-104. 2006.

GIARETTA, N. et al. Myoglobin as marker in meat adulteration: A UPLC method for determining the presence of pork meat in raw beef burger. **Food Chemistry**, v. 141, n. 3, p. 1814–1820, 1 dez. 2013.

GIROLAMI, A.; NAPOLITANO, F.; FARAONE, D.; BRAGHIERI, A. Measurement of meat color using a computer vision system. **Meat Science**, v. 93, n. 1, p. 111-118, 1 jan. 2013.

GOLDSCHMIDT, RONALDO RIBEIRO. "Uma Introdução à Inteligência Computacional: fundamentos, ferramentas e aplicações." **Rio de Janeiro Brasil: IST-Rio**. p. 32. 2010.

GÓMEZ-DE-ANDA, F.; DORANTES-ÁLVAREZ, L.; GALLARDO-VELÁZQUEZ, T.; OSORIO-REVILLA, G.; CALDERÓN-DOMÍNGUEZ, G.; LABAT, P. M.; DE-LA-ROSA-ARANA, J. L. Determination of Trichinella spiralis in pig muscles using Mid-Fourier Transform Infrared Spectroscopy (MID-FTIR) with Attenuated Total Reflectance (ATR) and Soft Independent Modeling of Class Analogy (SIMCA). **Meat Science**, v. 91, n. 3, p. 240-246, jul. 2012.

GOTTESMANN, P.; HAMM, R. New biochemical methods of differentiating between fresh meat and thawed, frozen meat. **Fleischwirtschaft**, 1983.

GOU, P.; SANTOS-GARCES, E.; HØY, M.; WOLD, J. P.; LILAND, K. H.; FULLADOSA, E. Feasibility of NIR interactance hyperspectral imaging for on-line measurement of crude composition in vacuum packed dry-cured ham slices. **Meat science**, v. 95, n. 2, p. 250-255, 2013.

GRANATO D.; BRANCO G. F.; NAZZARO F.; CRUZ A. G.; AND F. J. A. . Functional Foods and Nondairy Probiotic Food Development: Trends, Concepts, and Products. Comprehensive Reviews In **Food Science and Food Safety**, v. 9, p. 292-302, 2010.

GRUNERT, T.; STEPHAN, R.; EHLING-SCHULZ, M.; JOHLER, S. Fourier Transform Infrared Spectroscopy enables rapid differentiation of fresh and frozen/thawed chicken. **Food Control**, v. 60, p. 361-364, fev. 2016.

HAI, Z.; WANG, J. Electronic nose and data analysis for detection of maize oil adulteration in sesame oil, **Sensors Actuators B: Chemical**, 119: 449–455, 2006.

HE, H.-J.; SUN, D.-W. Hyperspectral imaging technology for rapid detection of various microbial contaminants in agricultural and food products. **Trends in Food Science & Technology**, v. 46, n. 1, p. 99–109, nov. 2015.

HERNÁNDEZ-CHÁVEZ, J. F., GONZÁLEZ-CÓRDOVA, A. F., RODRÍGUEZ-RAMÍREZ, R., & VALLEJO-CORDOBA, B. et al. Development of a polymerase chain reaction and capillary gel electrophoresis method for the detection of chicken or turkey meat in heat-treated pork meat mixtures. **Analytica Chimica Acta**, v. 708, n. 1–2, p. 149–154, 5 dez. 2011.

HSU, C. P. S. Infrared Spectroscopy. In: SETTLE, F. A. (Ed.). Handbook of Instrumental Techniques for Analytical Chemistry. First ed. Michigan: **Prentice Hall PTR**, 1997. p. 257-283. 1997.

HU, M. H.; DONG, Q. L.; LIU, B. L.; OPARA, U. L. Prediction of mechanical properties of blueberry using hyperspectral interactance imaging. **Postharvest Biology and Technology**, v. 115, p. 122-131, 1 maio 2016.

HUANG, H.; LIU, L.; NGADI, M. O. Prediction of pork fat attributes using NIR Images of frozen and thawed pork. **Meat Science**, v. 119, 2016.

HUANG, H.; LIU, L.; NGADI, M. O.; GARIÉPY, C. Rapid and non-invasive quantification of intramuscular fat content of intact pork cuts. **Talanta**, v. 119, 2014.

IQBAL, A.; SUN, D.-W.; ALLEN, P. Prediction of moisture, color and pH in cooked, pre-sliced turkey hams by NIR hyperspectral imaging system. **Journal of Food Engineering**, v. 117, n. 1, p. 42-51, jul. 2013.

JATURASITHA, S., SRIKANCHAI, T., KREUZER, M., & WICKE, M. Differences in carcass and meat characteristics between chicken indigenous to northern Thailand (Black-boned and Thai native) and imported extensive breeds (Bresse and Rhode Island Red). **Poultry Science**, v. 87, n. 1, p. 160-169, 2008.

JIANG, H.; YOON, S. C.; ZHUANG, H.; WANG, W.; LAWRENCE, K. C.; YANG, Y.

Tenderness classification of fresh broiler breast fillets using visible and near-infrared hyperspectral imaging. **Meat Science**, v. 139, p. 82-90, 1 maio 2018.

KAMRUZZAMAN, M.; BARBIN, D.; ELMASRY, G.; SUN, D. W.; ALLEN, P. Potential of hyperspectral imaging and pattern recognition for categorization and authentication of red meat. **Innovative Food Science & Emerging Technologies**, v. 16, p. 316-325, out. 2012b

KAMRUZZAMAN, M.; ELMASRY, G.; SUN, D. W.; ; ALLEN, P. Prediction of some quality attributes of lamb meat using near-infrared hyperspectral imaging and multivariate analysis. **Analytica Chimica Acta**, v. 714, p. 57-67, 2012a.

KAMRUZZAMAN, M.; ELMASRY, G.; SUN, D. W.; ALLEN, P. Non-destructive assessment of instrumental and sensory tenderness of lamb meat using NIR hyperspectral imaging. **Food Chemistry**, v. 141, n. 1, 2013.

KAMRUZZAMAN, M.; MAKINO, Y.; OSHITA, S. Rapid and non-destructive detection of chicken adulteration in minced beef using visible near-infrared hyperspectral imaging and machine learning. **Journal of Food Engineering**, v. 170, p. 8-15, 1 fev. 2016.

KAMRUZZAMAN, M.; MAKINO, Y.; OSHITA, S.; LIU, S. Assessment of Visible Near-Infrared Hyperspectral Imaging as a Tool for Detection of Horsemeat Adulteration in Minced Beef. **Food and Bioprocess Technology**, v. 8, n. 5, p. 1054–1062, 1 maio 2015.

KAMRUZZAMAN, M., SUN, D. W., ELMASRY, G., & ALLEN, P. Fast detection and visualization of minced lamb meat adulteration using NIR hyperspectral imaging and multivariate image analysis. **Talanta**, v. 103, 2013.

KANDPAL, L. M.; LEE, H.; KIM, M. S.; MO, C.; CHO, B. K. Hyperspectral reflectance imaging technique for visualization of moisture distribution in cooked chicken breast. **Sensors (Basel, Switzerland)**, v. 13, n. 10, 2013.

KENNARD, R. W.; STONE, L. A. Computer aided design of experiments. **Technometrics**, v. 11, n. 1, p. 137-148, 1969.

KIM, G. D.; SEO, J. K.; YUM, H. W.; JEONG, J. Y.; YANG, H. S. Protein markers for discrimination of meat species in raw beef, pork and poultry and their mixtures. **Food chemistry**, v. 217, p. 163-170, 2017.

KONIECZKA, P.; CZAUDERNA, M.; SMULIKOWSKA, S. The enrichment of chicken meat with omega-3 fatty acids by dietary fish oil or its mixture with rapeseed or flaxseed—Effect of feeding duration: Dietary fish oil, flaxseed, and rapeseed and n-3 enriched broiler meat. **Animal Feed Science and Technology**, v. 223, p. 42–52, 1 jan. 2017.

KUMAR, S.; MITTAL, G. S. Rapid detection of microorganisms using image processing parameters and neural network. **Food and Bioprocess Technology**, v. 3, n. 5, p. 741-751, 2010.

KUMAR, R. P.; RANI, M. S. Chemical composition of chicken of various commercial brands available in market. **IOSR-JAVS**, v. 7, n. 7, p. 22-26, 2014.

LAWRENCE, K. C. et al. *C p h i s a i*. v. 46, n. 2, p. 513–521, 2003.

LEBEDEV, A. V.; WESTMAN, E.; VAN WESTEN, G. J. P.; KRAMBERGER, M. G., LUNDERVOLD, A.; AARSLAND, D.; ...; VELLAS, B. Random Forest ensembles for detection and prediction of Alzheimer's disease with a good between-cohort robustness. **NeuroImage: Clinical**, v. 6, p. 115–125, 1 jan. 2014.

LESIÓW, T.; XIONG, Y. L. A simple, reliable and reproductive method to obtain experimental pale, soft and exudative (PSE) pork. **Meat science**, v. 93, n. 3, p. 489–94, mar. 2013.

LI, X.; FENG, F.; GAO, R.; WANG, L.; QIAN, Y.; LI, C.; ZHOU, G. Application of near infrared reflectance (NIR) spectroscopy to identify potential PSE meat. **Journal of the Science of Food and Agriculture**, 96(9), 3148-3156. 2016.

LUBIS, H. N.; MOHD-NAIM, N. F.; ALIZUL, N. N.; AHMED, M. U. From market to food plate: Current trusted technology and innovations in halal food analysis. **Trends in Food Science & Technology**, 58, 55-68. 2016.

LIU, C.; YANG, S. X.; DENG, L. Determination of internal qualities of Newhall navel oranges based on NIR spectroscopy using machine learning. **Journal of Food Engineering**, v. 161, p. 16-23, 1 set. 2015.

LIU, D.; QU, J.; SUN, D. W.; PU, H.; ZENG, X. A. Non-destructive prediction of salt contents and water activity of porcine meat slices by hyperspectral imaging in a salting process. **Innovative Food Science & Emerging Technologies**, v. 20, p. 316-323, 2013.

LIU, J. H.; SUN, X.; YOUNG, J. M.; BACHMEIER, L. A.; NEWMAN, D. J. Predicting pork loin intramuscular fat using computer vision system. **Meat science**, 143, 18-23. 2018.

LIN, W.; PENG, Y.. A portable device for rapid nondestructive detection of fresh meat quality. In: **Sensing for Agriculture and Food Quality and Safety VI**. International Society for Optics and Photonics, 2014. p. 91080Q.

LIU, Y.; CHEN, Y. R. Two-dimensional correlation spectroscopy study of visible and near-infrared spectral variations of chicken meats in cold storage. **Applied Spectroscopy**, v. 54, n. 10, p. 1458-1470, 2000.

LIU, Y.; GAO, R.; HAO, Y.; SUN, X.; OUYANG, A. Improvement of Near-Infrared Spectral Calibration Models for Brix Prediction in “Gannan” Navel Oranges by a Portable Near-Infrared Device. **Food and Bioprocess Technology**, v. 5, n. 3, p. 1106-1112, 15 abr. 2012.

LONERGAN, S. M.; DEEB, N.; FEDLER, C. A.; LAMONT, S. J. Breast meat quality and composition in unique chicken populations. **Poultry Science**, v. 82, n. 12, p. 1990-1994, 2003.

MADEIRA, L. A.; SARTORI, J. R.; SALDANHA, É. S. P. B.; PIZZOLANTE, C. C.; SILVA, M. D. P.; MENDES, A. A.; Takahashi, S. E; SOLARTE, W. V. N. Morfologia das fibras musculares esqueléticas de frangos de corte de diferentes linhagens criados em sistemas de confinamento e semiconfinamento. **Revista Brasileira de Zootecnia**, v. 35, n. 6, p. 2322–2332, 2006.

MANDLI, J., FATIMI, I. E.; SEDDAOUI, N.; AMINE, A. Enzyme immunoassay

(ELISA/immunosensor) for a sensitive detection of pork adulteration in meat. **Food Chemistry**, v. 255, p. 380–389, 30 jul. 2018.

MARQUES FILHO, OGÊ; NETO, HUGO VIEIRA. **Processamento digital de imagens**. Brasport, 1999.

MARÇAL, D. A.; DE ABREU, R. C.; CHEUNG, T. L.; KIEFER, C. Consumo da carne suína no Brasil: Aspectos simbólicos como determinantes dos comportamentos. **Revista em Agronegócio e Meio Ambiente**, v. 9, n. 4, p. 989–1005, 2016.

MEYER, G. E.; SUBBIAH, J. Three dimensional chemometric analyses of hyperspectral images for beef tenderness forecasting. **Journal of Food Engineering**, v. 169, p. 309–320, jan. 2016.

MICHIE, D. Methodologies from Machine Learning in Data Analysis and Software. **The Computer Journal**, v. 34, n. 6, p. 559–565, 1991.

MILLER, J. N.; MILLER, J. C. *Statistics and Chemometrics for Analytical Chemistry*. London: Prentice Hall. 2000.

MOREIRA, É. L. S. Composição Centesimal e Aspectos Físicos da Carne do Peito, da Coxa e da Sobrecoxade Frangos Alimentados com Dietas Contendo Erva- Mate (*Ilex paraguariensis*). Trabalho de Conclusão do curso em Medicina Veterinária. **Universidade de Brasília Faculdade de agronomia e Medicina Veterinária**, pag. 42. 2015.

MUNCK, L.; JESPERSEN, B. M.; RINNAN, Å.; SEEFELDT, H. F.; ENGELSEN, M. M., NØRGAARD, L.; ENGELSEN, S. B. A physiochemical theory on the applicability of soft mathematical models-experimentally interpreted. **Journal of Chemometrics**, v. 24, n. 7–8, 2010.

MUÑOZ, I.; RUBIO-CELORIO, M.; GARCIA-GIL, N.; GUÀRDIA, M. D.; FULLADOSA, E. Computer image analysis as a tool for classifying marbling: A case study in dry-cured ham. **Journal of Food Engineering**, v. 166, p. 148–155, 1 dez. 2015.

MURPHY, R. Y.; MARKS, B. P. Effect of meat temperature on proteins, texture, and cook loss for ground chicken breast patties. **Poultry Science**, v. 79, n. 1, p. 99-104, 2000.

NAGANATHAN, G. K.; GRIMES, L. M.; SUBBIAH, J.; CALKINS, C. R.; SAMAL, A.; MEYER, G. E. Partial least squares analysis of near-infrared hyperspectral images for beef tenderness prediction. **Sensing and Instrumentation for Food Quality and Safety**, v. 2, n. 3, p. 178–188, 2008.

NAGANATHAN, G. K.; CLUFF, K.; SAMAL, A.; CALKINS, C. R.; JONES, D. D.; MEYER, G. E.; SUBBIAH, J. Three dimensional chemometric analyses of hyperspectral images for beef tenderness forecasting. **Journal of Food Engineering**, v. 169, p. 309–320, 2016.

NETO, B. W. Parâmetros de qualidade de lubrificantes e óleo de oliva através de espectroscopia vibracional, calibração multivariada e seleção de variáveis / Tese – **Universidade Estadual de Campinas, Instituto de Química**. p. 130, 2005.

NIXON, Mark S.; AGUADO, Alberto S.. **Feature Extraction & Image Processing for Computer Vision**. 3. Ed. 2000.

NOLASCO PEREZ, I. M.; BADARÓ, A. T.; BARBON JR, S.; BARBON, A. P. A.; POLLONIO, M. A. R.; BARBIN, D. F. Classification of Chicken Parts Using a Portable Near-Infrared (NIR) Spectrophotometer and Machine Learning. **Applied Spectroscopy**, v. 0, n. 0, p. 370281878887, 2018.

NOURI-AHMADABADI, H.; OMID, M.; MOHTASEBI, S. S.; FIROUZ, M. S. Design, development and evaluation of an online grading system for peeled pistachios equipped with machine vision technology and support vector machine. **Information Processing in Agriculture**, v. 4, n. 4, p. 333-341, 1 dez. 2017.

OLIVERI, P.; LÓPEZ, M. I.; CASOLINO, M. C.; RUISÁNCHEZ, I.; CALLAO, M. P.; MEDINI, L.; LANTERI, S. Partial least squares density modeling (PLS-DM) – A new class-modeling strategy applied to the authentication of olives in brine by near-infrared spectroscopy. **Analytica Chimica Acta**, v. 851, p. 30-36, 3 dez. 2014.

OSBORNE, B. G., FEARN, T., HINDLE, P. H. Practical NIR spectroscopy with applications in food and beverage analysis, 2nd. ed. New York, USA: Longman Scientific & Technical, p. 227.1993

OTSU, N. A threshold selection method from gray-level histograms. **IEEE transactions on systems, man, and cybernetics**, 9(1), 62-66. 1979.

PALLOTTINO, F.; MENESATTI, P.; COSTA, C.; PAGLIA, G.; DE SALVADOR, F. R.; LOLLETTI, D. Image analysis techniques for automated hazelnut peeling determination. **Food and Bioprocess Technology**, v. 3, n. 1, p. 155-159, 2010.

PASQUINI, C. Near infrared spectroscopy: Fundamentals, practical aspects and analytical applications. **Journal of the Brazilian Chemical Society**, v. 14, n. 2, p. 198–219, 2003.

PASQUINI, C. Near infrared spectroscopy: A mature analytical technique with new perspectives – A review. **Analytica Chimica Acta**, v. 1026, p. 8–36, 5 out. 2018.

PINO, L. M. (ESCOLA S. DE A. "LUIZ DE Q. U. DE S. P. **Estabilidade oxidativa da carne de frangos alimentados com diferentes fontes lipídicas, armazenada sob congelamento**. pag. 72. 2005.

PINTO, L. A. D. M.; PINTO, M. D. M.; BOVO, J.; MATEUS, G. A. P.; TAVRES, F. D. O.; BAPTISTA, A. T. A.; HIRATA, A. K. Aspectos ambientais do abate de aves: uma revisão. **Revista UNINGÁ REVIEW**, v. 22, n. 3, p. 44–50, 2015.

PIZARRO, C.; RODRÍGUEZ-TECEDOR, S.; PÉREZ-DEL-NOTARIO, N.; ESTEBAN-DÍEZ, I.; GONZÁLEZ-SÁIZ, J. M. Classification of Spanish extra virgin olive oils by data fusion of visible spectroscopic fingerprints and chemical descriptors', **Food Chemistry. Elsevier**, 138(2–3), pp. 915–922. doi: 10.1016/J.FOODCHEM.2012.11.087. 2013.

POREP, J. U.; KAMMERER, D. R., ; CARLE, R. On-line application of near infrared (NIR) spectroscopy in food production. **Trends in Food Science & Technology**, v. 46, n. 2, p. 211-230, 2015.

PRIETO, N.; AALHUS, J. L.; LOPEZ-CAMPOS, O.; ZIJLSTRA, R. T.; JUÁREZ, M. Discrimination of beef dark cutters and enhanced quality pork using visible and near infrared spectroscopy. **Meat Science**, v. 101, p. 144-145, mar. 2015.

PRIETO, N.; LOPEZ-CAMPOS, O.; AALHUS, J. L.; DUGAN, M. E. R., JUAREZ, M.; UTTARO, B. Use of near infrared spectroscopy for estimating meat chemical composition, quality traits and fatty acid content from cattle fed sunflower or flaxseed. **Meat science**, v. 98, n. 2, p. 279–88, out. 2014.

PU, H.; SUN, D. W.; MA, J.; LIU, D.; KAMRUZZAMAN, M. Hierarchical variable selection for predicting chemical constituents in lamb meats using hyperspectral imaging. **Journal of Food Engineering**, v. 143, 2014.

PULLANAGARI, R. R.; YULE, I. J.; AGNEW, M. On-line prediction of lamb fatty acid composition by visible near infrared spectroscopy. **Meat science**, v. 100, p. 156–63, fev. 2015.

QUEVEDO, R. A.; AGUILERA, J. M.; PEDRESCHI, F. Color of Salmon Fillets By Computer Vision and Sensory Panel. **Food and Bioprocess Technology**, v. 3, n. 5, p. 637–643, 26 out. 2010.

RADY, A.; ADEDEJI, A. Assessing different processed meats for adulterants using visible-near-infrared spectroscopy. **Meat Science**, v. 136, p. 59–67, 1 fev. 2018. doi: 10.1016/J.MEATSCI.2017.10.014.

RAHBARI, M.; HAMDAMI, N.; MIRZAEI, H.; JAFARI, S. M.; KASHANINEJAD, M.; KHOMEIRI, M. Effects of high voltage electric field thawing on the characteristics of chicken breast protein. **Journal of Food Engineering**, v. 216, p. 98-106, 2018.

REIS, M. M.; ROSENVOLD, K. Early on-line classification of beef carcasses based on ultimate pH by near infrared spectroscopy. **Meat Science**, v. 96, n. 2, p. 862–869, 1 fev. 2014.

RODRIGUEZ-GALIANO, V. F.; GHIMIRE, B.; ROGAN, J.; CHICA-OLMO, M.; RIGOL-SANCHEZ, J. P. An assessment of the effectiveness of a random forest classifier for land-cover classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 67, p. 93–104, 1 jan. 2012.

ROMANO, A.; MASI, P.; CAVELLA, S. Visual evaluation of sliced Italian salami by image analysis. **Food Science and Nutrition**, v. 6, n. 1, p. 153–159, 2018.

ROPODI, A. I.; PANAGOU, E. Z.; NYCHAS, G.-J. E. Multispectral imaging (MSI): A promising method for the detection of minced beef adulteration with horsemeat. **Food Control**, v. 73, p. 57–63, mar. 2017.

SANDORY, C., BUCHET, R., LACHENAL, G. Principles of molecular vibrations for near-infrared spectroscopy. In Ozaki, Near- infrared spectroscopy in food science and technology, Edyted by Y., McClure, W. F., Christy, A. A. pag 11-46. 2007.

SANTOS PEREIRA, L. F.; BARBON, S.; VALOUS, N. A.; BARBIN, D. F. Predicting the ripening of papaya fruit with digital imaging and random forests, **Computers and Electronics in Agriculture**. Elsevier, 145, pp. 76–82. doi: 10.1016/J.COMPAG.2017.12.029. 2018.

SAMS, A. R. Poultry Meat Processing. **CRC Press Taylor & Francis Group**. New York Washington, D.C. pag. 345. 2001

SARAH, S. A.; FARADALILA, W. N.; SALWANI, M. S.; AMIN, I.; KARSANI, S. A.; SAZILI, A. Q. LC-QTOF-MS identification of porcine-specific peptide in heat treated pork identifies candidate markers for meat species determination. **Food Chemistry**, v. 199, p. 157–164, 15 maio 2016.

SARCINELLI, M. F.; VENTURINI, K. S.; SILVA, L. C. DA. Características da Carne Suína. **Revista Brasileira de Zootecnia**, v. 1, n. 1, p. 1–7, 2007.

SAVITZKY, A.; GOLAY, M. J. Smoothing and differentiation of data by simplified least squares procedures. **Analytical chemistry**, v. 36, n. 8, p. 1627–1639, 1964.

SERRANO, S.; PERÁN, F.; JIMÉNEZ-HORNERO, F. J.; DE RAVÉ, E. G. Multifractal analysis application to the characterization of fatty infiltration in Iberian and White pork sirloins. **Meat Science**, v. 93, n. 3, p. 723–732, 1 mar. 2013

SHAO, Y.; LI, Y.; JIANG, L.; PAN, J.; HE, Y.; DOU, X. Identification of pesticide varieties by detecting characteristics of *Chlorella pyrenoidosa* using Visible/Near infrared hyperspectral imaging and Raman microspectroscopy technology. **Water research**, v. 104, p. 432–440, 1 nov. 2016.

SHERLOCK, R. A.; SMITH, L. A.; MITCHELL, R. S. Automatic oestrus detection from milking data - a preliminary investigation. **Proc NZ Society for Animal Production**, v. 65, p. 228–229, 1996.

SMITH, B. C. Fundamentals of Fourier Transform Infrared Spectroscopy. Second ed. New York, USA: CRC Press Taylor & Francis Group. 2001

SONG, S. Y.; LEE, Y. K.; KIM, I.-J. Sugar and acid content of Citrus prediction modeling using FT-IR fingerprinting in combination with multivariate statistical analysis. **Food chemistry**, v. 190, p. 1027–32, 1 jan. 2016.

SOUZA D. F. Application of infrared spectroscopy and multivariate analysis to predict quality parameters in soybean and quinoa. Tesis / **Universidade Estadual de Campinas, Faculdade de Engenharia de Alimentos** pag. 119. 2013.

SU, H.; SHA, K.; HANG, L.; ZHANG, Q.; XU, Y.; ZHANG, R.; Li, H.; SUN, B. Development of near infrared reflectance spectroscopy to predict chemical composition with a wide range of variability in beef. **Meat science**, v. 98, n. 2, p. 110–4, out. 2014.

SUN, X.; YOUNG, J.; LIU, J. H.; BACHMEIER, L.; SOMERS, R. M.; CHEN, K. J.; NEWMAN, D. Prediction of pork color attributes using computer vision system. **Meat Science**, v. 113, p. 62–64, 1 mar. 2016.

- SUN, X.; YOUNG, J.; LIU, J. H.; NEWMAN, D. Prediction of pork loin quality using online computer vision system and artificial intelligence model. **Meat Science**, v. 140, p. 72-77, 1 jun. 2018.
- TAO, F.; PENG, Y. A method for nondestructive prediction of pork meat quality and safety attributes by hyperspectral imaging technique. **Journal of Food Engineering**, v. 126, p. 98–106, abr. 2014.
- TAYLOR, J. C.; SUTTER, C.; ONTAI, L. L.; NISHINA, A.; ZIDENBERG-CHERR, S. Feasibility and reliability of digital imaging for estimating food selection and consumption from students' packed lunches. **Appetite**, v. 120, p. 196–204, 2018.
- TEIMOURI, N.; OMID, M.; MOLLAZADE, K.; MOUSAZADEH, H.; ALIMARDANI, R.; & KARSTOFT, H. On-line separation and sorting of chicken portions using a robust vision-based intelligent modelling approach. **Biosystems Engineering**, v. 167, p. 8-20, 2018.
- TRINDERUP, C. H.; DAHL, A.; JENSEN, K.; CARSTENSEN, J. M.; CONRADSEN, K. Comparison of a multispectral vision system and a colorimeter for the assessment of meat color. **Meat science**, v. 102, p. 1-7, April 2015.
- TROY, D. J.; TIWARI, B. K.; JOO, S. T. Health Implications of Beef Intramuscular Fat Consumption. **Korean Journal for Food Science of Animal Resources**, v. 36, n. 5, p. 577–582, 2016.
- USDA. Livestock and Poultry: World Markets and Trade On line: Foreign Agricultural Service 2018 (Available at [https://apps.fas.usda.gov/psdonline/circulars/livestock\\_poultry.pdf](https://apps.fas.usda.gov/psdonline/circulars/livestock_poultry.pdf) , access: 31-01-2019)
- VENTURINI, K. S.; SARCINELLI, M. F.; SILVA, L. D. Características da carne de frango. **Boletim Técnico-Pie-Ufes**, 1307. 2007.
- VEZZANI, E. Revestimentos para carne de frango pronta para consumo. **Aliment Tecnol**, 1(8), 110-2, 1986.
- VINCKE, D. et al. Analysis of collagen preservation in bones recovered in archaeological contexts using NIR Hyperspectral Imaging. **Talanta**, v. 125, p. 181–8, jul. 2014.
- WANG, W.; PALIWAL, J. Near-infrared spectroscopy and imaging in food quality and safety. **Sensing and instrumentation for food quality and safety**, v. 1, n. 4, p. 193-207, 2007.
- WANG, W.; PENG, Y.; SUN, H.; ZHENG, X.; WEI, W. Real-time inspection of pork quality attributes using dual-band spectroscopy. **Journal of Food Engineering**. Elsevier, 237, p. 103-109, doi: 10.1016/J.JFOODENG.2018.05.022. 2018.
- WATTANACHANT, S.; BENJAKUL, S.; LEDWARD, D. A. Composition, color, and texture of Thai indigenous and broiler chicken muscles. **Poultry science**, v. 83, n. 1, p. 123-128, 2004.
- WILLIAMS, P.; NORRIS, K. H. Near-infrared Technology in the Agricultural and Food Industries. 2nd. ed. University of Wisconsin - Madison: American **Association of Cereal Chemists**, 2001. p. 296, 2001.

WOLD, J. P. On-line and non-destructive measurement of core temperature in heat treated fish cakes by NIR hyperspectral imaging. **Innovative Food Science & Emerging Technologies**, v. 33, p. 431–437, fev. 2016.

WOLD, J. P.; JAKOBSEN, T.; KRANE, L. Wold, J. P., Jakobsen, T. and Krane, L. (1996) Atlantic Salmon Average Fat Content Estimated by Near-Infrared Transmittance Spectroscopy, **Journal of Food Science** 61(1), pp. 1–4. 1996

WOLD, J. P.; KERMIT, M.; SEGTMAN, V. H. Chemical imaging of heterogeneous muscle foods using near-infrared hyperspectral imaging in transmission mode. **Applied Spectroscopy**, v. 70, n. 6, 2016.

WOLD, J. P.; VEISETH-KENT, E.; HØST, V.; LØVLAND, A. Rapid on-line detection and grading of wooden breast myopathy in chicken fillets by near-infrared spectroscopy. **PLOS ONE**, v. 12, n. 3, p. e0173384, 9 mar. 2017.

WU, J.; PENG, Y.; LI, Y.; WANG, W.; CHEN, J.; DHAKAL, S. Prediction of beef quality attributes using VIS/NIR hyperspectral scattering imaging technique. **Journal of Food Engineering**, v. 109, n. 2, p. 267–273, mar. 2012.

XIE, A.; SUN, D. W.; XU, Z.; ZHU, Z. Rapid detection of frozen pork quality without thawing by Vis-NIR hyperspectral imaging technique. **Talanta**, v. 139, p. 208–15, 1 jul. 2015.

XIE, A.; SUN, D. W.; ZHU, Z.; PU, H. Nondestructive Measurements of Freezing Parameters of Frozen Porcine Meat by NIR Hyperspectral Imaging. **Food and Bioprocess Technology**, v. 9, n. 9, 2016.

XIONG, Z.; SUN, D. W.; PU, H.; ZHU, Z.; LUO, M. Combination of spectra and texture data of hyperspectral imaging for differentiating between free-range and broiler chicken meats. **LWT - Food Science and Technology**, v. 60, n. 2, p. 649–655, mar. 2015b.

XIONG, Z.; SUN, D. W.; XIE, A.; HAN, Z.; WANG, L. Potential of hyperspectral imaging for rapid prediction of hydroxyproline content in chicken meat. **Food chemistry**, v. 175, p. 417–422, 15 maio 2015c.

XIONG, Z.; XIE, A.; SUN, D. W.; ZENG, X. A.; LIU, D. Applications of Hyperspectral Imaging in Chicken Meat Safety and Quality Detection and Evaluation: A Review. **Critical Reviews in Food Science and Nutrition**, v. 55, n. 9, p. 1287–1301, 2015.

YANG, Q.; SUN, D.-W.; CHENG, W. Development of simplified models for nondestructive hyperspectral imaging monitoring of TVB-N contents in cured meat during drying process. **Journal of Food Engineering**, v. 192, p. 53–60, 1 jan. 2017.

YANG, Y.; ZHUANG, H.; YOON, S. C.; WANG, W.; JIANG, H.; JIA, B. Rapid classification of intact chicken breast fillets by predicting principal component score of quality traits with visible/near-Infrared spectroscopy. **Food Chemistry**, v. 244, p. 184–189, 1 abr. 2018.

YE, X.; IINO, K.; ZHANG, S. Monitoring of bacterial contamination on chicken meat surface using a novel narrowband spectral index derived from hyperspectral imagery data. **Meat science**, v. 122, p. 25–31, dez. 2016.

YAVARI, A.; HAMED, M.; HAGHBIN, S. Retraction notice to: “VIS/NIR hyperspectroscopy technique for the measurement of moisture and fat contents of breaded-fried chicken nuggets” [Food Chem. 127 (2011) 645–650]. **Food Chemistry**, v. 138, n. 1, p. 421, maio 2013.

ZHAO, M.; DOWNEY, G., & O'DONNELL, C. P. Detection of adulteration in fresh and frozen beefburger products by beef offal using mid-infrared ATR spectroscopy and multivariate data analysis. **Meat science**, 96(2), 1003-1011. 2014.

ZHENG, W.; FU, X.; YING, Y. Spectroscopy-based food classification with extreme learning machine. **Chemometrics and Intelligent Laboratory Systems**, v. 139, p. 42–47, 2014.

ZHENG, X. C.; LI, Y. Y.; PENG, Y. K.; WANG, W. X.; WANG, F.; YANG, Y. Improvement of nondestructive detection system of beef quality based on visible/near infrared spectroscopy. **Nongye Jixie Xuebao/Transactions of the Chinese Society for Agricultural Machinery**, v. 47, p. 332-339, 2016.

ZHENG, X.; LI, Y.; WEI, W.; PENG, Y. Detection of adulteration with duck meat in minced lamb meat by using visible near-infrared hyperspectral imaging', **Meat Science**. Elsevier. doi: 10.1016/J.MEATSCI.2018.11.005. 2019.

ZHOU, L. J.; WU, H.; LI, J. T.; WANG, Z. Y.; ZHANG, L. Y. Determination of fatty acids in broiler breast meat by near-infrared reflectance spectroscopy. **Meat science**, v. 90, n. 3, p. 658–64, mar. 2012.

ZHUANG, H.; SAVAGE, E. M. Postmortem aging and freezing and thawing storage enhance ability of early deboned chicken pectoralis major muscle to hold added salt water 1. **Poultry Science**, v. 91, n. 5, p. 1203–1209, 2012.

## **ANEXOS**

## **A. ANEXO 1 - MEMÓRIA DO PERÍODO DE DOUTORADO**

Irene Marivel Nolasco Pérez, participou do programa de pós-graduação como doutoranda na UNICAMP no Departamento de Engenharia de Alimentos (DEA) da Faculdade de Engenharia de Alimentos (FEA) no período de março de 2015 a fevereiro de 2019 com uma duração de 48 meses, com auxílio financeiro da CAPES código financeiro 001, após aprovação no processo seletivo em Março 2015.

As atividades de pesquisa apresentadas foram realizadas durante o trabalho no grupo do laboratório LINA (Laboratório de Inovação em Alimentos), sob orientação do Professor Doutor Douglas Fernandes Barbin. As disciplinas cursadas durante o período do doutorado foram: AP417-Modelagem e respostas de Sistemas Dinâmicos; TP159 - Tópicos Especiais em Engenharia de Alimentos; TP376 - Nanotecnologia de Alimentos; QP934 - Tópicos Especiais em Físico-Química X; IQ382 - Otimização de Processos; AP630 - Cinética de secagem; Métodos Matemáticos na Engenharia de Alimentos.

A aluna participou do Programa de Estágio Docente - PED C com atividades de apoio parcial à docência da disciplina Processos Tecnológicos I, atuando como bolsista entre 08/2015 e 12/2015 por 8 h semanais, e como voluntária na disciplina Laboratório de Operações Unitárias no 1º semestre de 2016, por 8h semanais.

Participou entre 2016 e 2018 como avaliadora de trabalhos inscritos na área de Tecnológicas e Ciências no XXIV, XXV e XXVI Congresso Internacional de Iniciação Científica da UNICAMP.

As pesquisas referentes, tanto ao projeto de Doutorado, quanto às parcerias com outros integrantes do grupo de pesquisa do LINA e outros grupos na universidade de Londrina, resultaram em 2 artigos completos, sendo 1 artigo publicado e 1 submetido, 1 resumo no encontro científico internacional, detalhados a seguir:

### **Artigos completos**

**I.- NOLASCO PEREZ, I.M., BADARÓ, A. T., BARBON Jr, S., BARBON, A. P. A., POLLONIO, M. A. R., & BARBIN, D. F. (2018). “Classification of Chicken Parts Using a Portable Near-Infrared (NIR) Spectrophotometer and Machine Learning”. *Applied spectroscopy*, <https://doi.org/10.1177/0003702818788878>, 2018. Publicado *on-line*.**

**II.-** NOLASCO PEREZ, I.M., “Comparison of rapid techniques for classification of ground meat” *Jan.. 2019* artigo submetido à revista Biosystems Engineering.

**Resumos publicados em congressos internacionais**

**I.-** NOLASCO PEREZ, I.M., FERREIRA DE SOUZA G., BARBIN D. F. “Diferenciação de la carne de ave por espectroscopia infrarojo cercano”. International Scientific Meeting (ECI-PERÙ), realizado enero 2017 (*ECI*).

## B. ANEXO 2 COMPROVANTE DO ARTIGO PUBLICADO



# RightsLink®

[Home](#)
[Create Account](#)
[Help](#)



**Title:** Classification of Chicken Parts Using a Portable Near-Infrared (NIR) Spectrophotometer and Machine Learning

**Author:** Irene Marivel Nolasco Perez, Amanda Teixeira Badaró, Sylvio Barbon, et al

**Publication:** Applied Spectroscopy

**Publisher:** SAGE Publications

**Date:** 12/01/2018

Copyright © 2018, © SAGE Publications

**LOGIN**

If you're a **copyright.com** user, you can login to RightsLink using your copyright.com credentials.

Already a **RightsLink** user or want to [learn more?](#)

### Gratis Reuse

Permission is granted at no cost for use of content in a Master's Thesis and/or Doctoral Dissertation. If you intend to distribute or sell your Master's Thesis/Doctoral Dissertation to the general public through print or website publication, please return to the previous page and select 'Republish in a Book/Journal' or 'Post on intranet/password-protected website' to complete your request.

[BACK](#)
[CLOSE WINDOW](#)

Copyright © 2018 [Copyright Clearance Center, Inc.](#) All Rights Reserved. [Privacy statement](#). [Terms and Conditions](#). Comments? We would like to hear from you. E-mail us at [customer care@copyright.com](mailto:customer care@copyright.com)

### C. ANEXO 3 APRESENTAÇÃO DA DISTRIBUIÇÃO DAS AMOSTRAS

|    | Calibração | Repetições |    | Validação | Repetições |
|----|------------|------------|----|-----------|------------|
| 1  | 0%         | 5          | 1  | 0%        | 5          |
| 2  | 2%         | 5          |    |           |            |
| 3  | 4%         | 5          | 2  | 4%        | 5          |
| 4  | 6%         | 5          |    |           |            |
| 5  | 8%         | 5          | 3  | 8%        | 5          |
| 6  | 10%        | 5          |    |           |            |
| 7  | 12%        | 5          | 4  | 12%       | 5          |
| 8  | 14%        | 5          |    |           |            |
| 9  | 16%        | 5          | 5  | 16%       | 5          |
| 10 | 18%        | 5          |    |           |            |
| 11 | 20%        | 5          | 6  | 20%       | 5          |
| 12 | 22%        | 5          |    |           |            |
| 13 | 24%        | 5          | 7  | 24%       | 5          |
| 14 | 26%        | 5          |    |           |            |
| 15 | 28%        | 5          | 8  | 28%       | 5          |
| 16 | 30%        | 5          |    |           |            |
| 17 | 32%        | 5          | 9  | 32%       | 5          |
| 18 | 34%        | 5          |    |           |            |
| 19 | 36%        | 5          | 10 | 36%       | 5          |
| 20 | 38%        | 5          |    |           |            |
| 21 | 40%        | 5          | 11 | 40%       | 5          |
| 22 | 42%        | 5          |    |           |            |
| 23 | 44%        | 5          | 12 | 44%       | 5          |
| 24 | 46%        | 5          |    |           |            |
| 25 | 48%        | 5          | 13 | 48%       | 5          |
| 26 | 50%        | 5          | 14 | 50%       | 5          |
| 27 | 100%       | 5          | 15 | 100%      | 5          |