



UNIVERSIDADE  
ESTADUAL DE LONDRINA

---

BRUNA CAROLINE GERONIMO

**IDENTIFICAÇÃO E CLASSIFICAÇÃO DE *WOODEN BREAST*  
EM FRANGOS DE CORTES POR MÉTODOS NÃO  
DESTRUTIVOS**

---

Londrina  
2017

BRUNA CAROLINE GERONIMO

**IDENTIFICAÇÃO E CLASSIFICAÇÃO DE *WOODEN BREAST*  
EM FRANGOS DE CORTES POR MÉTODOS NÃO  
DESTRUTIVOS**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência de Alimentos da Universidade Estadual de Londrina como cumprimento às exigências parciais para obtenção do título de Mestre em Ciência de Alimentos.

Orientadora: Profa. Dra. Elza Louko Ida.

Londrina  
2017

### **Dados Internacionais de Catalogação-na-Publicação (CIP)**

G377i Geronimo, Bruna Caroline.

Identificação e classificação de wooden breast em frangos de cortes por métodos não destrutivos / Bruna Caroline Geronimo. - Londrina, 2017.  
76 f.: il.

Orientador: Elza Iouko Ida.

Dissertação (Mestrado em Ciência de Alimentos) - Universidade Estadual de Londrina, Centro de Ciências Agrárias, Programa de Pós-Graduação em Ciência Animal, 2017.

Inclui bibliografia.

1. Carne - Propriedades físico-química - Teses. 2. Carne de ave - Qualidade - Teses. 3. Espectroscopia de infravermelho - Teses. I. Ida, Elza Iouko. II. Universidade Estadual de Londrina. Centro de Ciências Agrárias. Programa de Pós-Graduação em Ciência de Alimentos. III. Título.

CDU 664.91

BRUNA CAROLINE GERONIMO

**IDENTIFICAÇÃO E CLASSIFICAÇÃO DE *WOODEN BREAST* EM  
FRANGOS DE CORTES POR MÉTODOS NÃO DESTRUTIVOS**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência de Alimentos da Universidade Estadual de Londrina como cumprimento às exigências parciais para obtenção do título de Mestre em Ciência de Alimentos.

**BANCA EXAMINADORA**

---

Orientadora: Profa. Dra. Elza Louko Ida  
Universidade Estadual de Londrina - UEL

---

Prof.Dr. Alexandre Oba  
Universidade Estadual de Londrina - UEL

---

Profa.Dra. Mayka Reghiany Pedrão  
Universidade Tecnológica Federal do Paraná –  
UTFPR

Londrina, 20 de setembro de 2017.

A Deus, pelo dom da vida, por me conceder a graça de vivenciar mais esta vitória.

Aos meus pais, José Luiz e Maria de Lourdes, pelo amor incondicional, por acreditar e apoiar os meus sonhos. Meus melhores exemplos de vida e amor!

À minha irmã Cintia, pelo incentivo e companheirismo!

A vocês dedico!

## **AGRADECIMENTOS**

À minha orientadora Profa. Dra. Elza Louko Ida pela sábia e preciosa orientação, dedicação e ensinamentos. Exemplo de pessoa e profissional que admiro muito.

Ao Prof. Dr. Massami Shimokomaki pela inestimável colaboração e sugestões para desenvolvimento deste trabalho.

Aos Professores Dr. Sylvio Barbon Júnior e Dr. Douglas Fernandes Barbin pela contribuição e ensinamentos para desenvolvimento deste trabalho.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo auxílio financeiro.

À COPACOL de Cafelândia-PR pela disponibilização das amostras cárneas e a todos os funcionários que auxiliaram na coleta.

Ao Departamento de Ciência e Tecnologia de Alimentos desta Instituição pela confiança e condições oferecidas para a realização deste trabalho.

Aos docentes do Programa de Mestrado e Doutorado em Ciência de Alimentos desta Instituição pelos ensinamentos e ajuda dispensada.

Aos funcionários do Departamento de Ciência e Tecnologia de Alimentos desta Instituição, em especial à Sandra Rezende, Patrícia e Alessandra pelo apoio técnico e administrativo.

Ao Pós-Doutor Rafael Humberto de Carvalho pela convivência, pela valiosa contribuição, sugestões e ponderações para desenvolvimento da pesquisa.

Aos integrantes do grupo de pesquisa da Profa. Dra. Elza Louko Ida, Cintia Ladeira Handa, Fábio Goscinski, Heloisa Gabriel Falcão, Marcela Fernanda Geton Guelfi, Mariah Benine Ramos Silva pelo trabalho em equipe, companheirismo e crescimento pessoal.

Aos demais colegas do Programa de Pós-Graduação em Ciência de Alimentos, pela amizade e pelos momentos agradáveis durante o mestrado.

A todos que direta ou indiretamente colaboraram com o desenvolvimento deste trabalho.

“A tua força e convicção não tem idade. O teu espírito é como qualquer teia de aranha. Atrás de cada linha de chegada, há uma de partida. Atrás de cada conquista, vem um novo desafio. Enquanto estiver vivo, sintá-se vivo [...]”.

**Madre Tereza de Calcutá**

GERONIMO, Bruna Caroline. **Identificação e classificação de *wooden breast* em frangos de cortes por métodos não destrutivos**. 2017. 76 f. Dissertação (Mestrado em Ciência de Alimentos) – Universidade Estadual de Londrina, 2016.

## RESUMO

O objetivo desse estudo foi identificar e classificar peitos de frango com a miopatia *wooden breast* (WB) utilizando o Sistema de Visão Computacional (CVS), informação espectral do infravermelho próximo (NIR) e caracterizar os parâmetros físico-químicos e tecnológicos de peitos de frango normal (N) e WB. Um total de 80 peitos (*pectoralis major* muscle) foi coletado em abatedouro comercial de aves e selecionados 40 como N e 40 como WB. Foram obtidas informações espectrais utilizando NIR e CVS. Posteriormente, os peitos N e WB de frango foram caracterizados por medidas físicoquímicas e tecnológicas. Combinando análises de imagens com o modelo de classificação da Máquina de Vetores de Suporte (SVM) usando recursos de intensidade e imagem de textura extraídos de fotos de peitos de frango, 91,83% foram corretamente classificados como N ou WB. Em comparação, o uso de informações espectrais do NIR alcançou 97,5% de precisão. Em relação às características físicoquímicas e tecnológicas, o WB de frango apresentou um aumento de 2,21% de umidade e 106,67% do teor de lipídios, e uma diminuição de 14,41% e 13,04% do teor de proteína e cinzas, respectivamente. Além disso, WB aumentou em 9,96%, 64,19% e 23,28% para  $L^*$ ,  $a^*$  e  $b^*$ , respectivamente; 1,91% para pH e 106,06% para perda de água por cozimento. A força de cisalhamento dos peitos de frango cru foi 49,51% mais rígido e, após o cozimento, foi 31,79% mais macio do que os peitos de frango N. CVS e NIR podem ser aplicados como métodos rápidos e não destrutivos para identificação e classificação de WB de frango em abatedouros.

**Palavras-chave:** Algoritmos. Imagem hiperespectral. Processamento de Imagens. Aprendizado de Máquina.

GERONIMO, B.C. **Identification and classification of Wooden Breast in broilers by non-destructive methods**. 2017. 76 p. Dissertation (Master's degree in Food Science) – Universidade Estadual de Londrina, Londrina, 2017.

### ABSTRACT

The aim of this study was to identify and classify chicken breasts with Wooden Breast (WB) myopathy using a Computer Vision System (CVS), spectral information from the near infrared (NIR) and to characterize physicochemical and technological parameters of Normal (N) and WB. A total of 80 breasts (*pectoralis major* muscle) was collected in commercial poultry slaughterhouse and selected 40 as N and 40 as WB. Spectral information using the NIR and CVS was obtained. Subsequently, N and WB of chickens were characterized by physicochemical and technological measures. Combining image analyses with Support Vector Machine (SVM) classification model using intensity and textural image features extracted from pictures of chicken breast, 91.83% were correctly classified as N or WB. In comparison, using NIR spectral information allowed for 97.5% of accuracy. Regarding the physicochemical and technological characteristics, WB of chicken showed an increase of 2.21% of the moisture and 106.67% of the lipid content, and a decrease of 14.41% and 13.04% of protein and ash contents, respectively. In addition, WB increased 9.96%, 64.19% and 23.28% for L \*, a \* and b \*, respectively; 1.91% for pH and 106.06 % for cooking loss. The shear force of raw WB of chicken was 49.51% hardness and, after cooking, was 31.79% softer than N chicken breast. CVS and NIR spectroscopy could be applied as a fast and non-destructive method for identification and classification of WB of chickens in slaughterhouses.

**Keywords:** Algorithms. Hyperspectral Image. Image processing. Machine learning.

## LISTA DE ABREVEATURAS E SIGLAS

a*	Componente vermelho-verde
ANN	Artificial neural networks
b*	Componente amarelo-azul
CL	Cooking loss
CRA	Capacidade de retenção de água
CVS	Computer vision system
L*	Luminosidade
LDA	Linear discriminant analysis
MLP	Multilayer perceptron
N	Normal
NIR	Espectroscopia de infravermelho próximo
PCA	Principal component analysis
RF	Random forest
ROI	Region of interest
SF	Shear force
Std	Standard deviation
SVM	Support vector machine
WB	<i>Wooden breast</i>
WHC	Water holding capacity
WS	<i>White striping</i>

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	10
<b>2</b>	<b>OBJETIVOS</b> .....	13
2.1	Objetivo Geral.....	13
2.2	Objetivos Específicos .....	13
<b>3</b>	<b>REVISÃO BIBLIOGRÁFICA</b> .....	14
3.1	Aspectos Gerais e Características de Wooden Breast em Frangos.....	14
3.1	Bioquímica e Composição Química de Carnes .....	19
3.2	Histologia Muscular dos Peitos de Frango .....	20
3.3	Propriedades Funcionais das Carnes.....	21
3.3.1	Qualidade da carne .....	21
3.3.2	Aparência .....	22
3.3.3	pH e capacidade de retenção de água.....	22
3.3.4	Textura .....	23
3.4	Espectroscopia de Infravermelho Próximo (NIR) e Análise de Imagem Digital.....	24
3.5	Árvore de Decisão .....	25
	<b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	27
<b>4</b>	<b>MATERIAL E MÉTODOS</b> .....	32
<b>5</b>	<b>RESULTADOS E DISCUSSÃO</b> .....	33
5.1	Artigo Científico .....	34
<b>6</b>	<b>CONCLUSÕES</b> .....	76

## 1 INTRODUÇÃO

A produção de aves no Brasil tem apresentado altos índices de crescimento. Os fatores associados à alta qualidade, sanidade e custo são imprescindíveis para que o Brasil seja atualmente o maior exportador mundial. De acordo com a Associação Brasileira de Proteína Animal (ABPA), o país exportou 4.384 mil toneladas de carne de frango em 2016, conferindo sua liderança neste quesito. Atualmente, o Brasil é o segundo maior produtor de aves com 12.900 mil toneladas de produção no ano de 2016, sendo os EUA o maior produtor mundial com 18.261 mil toneladas/ano. Ainda, de acordo com ABPA, o Paraná foi responsável por 35,85 % das exportações da carne de frango e o consumo foi de 41,1 kg per capita/ano. Devido a excelência destes produtos, o Brasil tem conquistado os mercados mais exigentes, sendo os principais importadores a União Europeia, Europa, Oceania, Oriente Médio, África, América e Ásia (ABPA, 2016).

Nos últimos 20 anos, tem sido observado um aumento na preferência pela carne do peito de frango. Para atender a crescente busca pelo consumidor, principalmente de países ocidentais, a seleção genética foi direcionada para escolha de aves com alto desenvolvimento e rendimento de peitos e pernas (PETRACCI et al., 2015). Desta forma, para atender à crescente demanda, há interesses em alcançar maior peso da ave em menor tempo, possibilitando a realização do abate com menor idade (HAVENSTEIN et al., 2003; PETRACCI et al., 2015), além de melhorar a taxa de conversão alimentar e reduzir a taxa de mortalidade sem redução da qualidade da carne ofertada. O aumento pela preferência do consumidor está associado ao baixo custo, propriedades dietéticas e nutritivas, diversidade e facilidade de preparo e ao fato de que a produção e consumo de aves não confrontam com fatores de ordem cultural ou religioso (VALCESCHINI, 2006; PETRACCI et al., 2015).

Nos últimos 30 anos, a intensa seleção genética associada a uma alimentação de alta energia possibilitou a obtenção de frangos com maior rendimento da carcaça, em particular, aumento do rendimento dos peitos de frangos e aumento da taxa de crescimento (HAVENSTEIN et al., 2003; PETRACCI et al., 2015; MUTRYN et al., 2015).

Entretanto, tais avanços têm contribuído para a incidência de anomalias na carne de peitos de frangos, comportamentos fisiológicos anormais, com

consequente danos ao tecido muscular que refletem na redução da qualidade da carcaça (SHIMOKOMAKI et al., 2006; MUTRYN et al., 2015; PETRACCI et al., 2015). Dentre as anomalias que provocam alterações na aparência, redução da qualidade tecnológica e nutritiva, com consequente aversão dos consumidores está o *wooden breast* (WB) recentemente reportado na Finlândia, Europa e EUA (KUTTAPPAN et al., 2012a; SIHVO et al., 2014; MUDALAL et al., 2015, MUTRYN et al., 2015) e também no Brasil. Devido às alterações macroscopicamente visíveis (SIHVO et al., 2014), há interesses em desvendar a etiologia dessas alterações para reduzir a incidência e diminuir seu impacto à economia, visto que os peitos de aves afetados são normalmente rejeitados pelos consumidores ou encaminhados para fabricação de produtos processados (MAZZONI et al., 2015; MUDALAL et al., 2015; TROCINO et al., 2015) gerando perdas econômicas significativas.

A detecção de peitos de frangos afetados por esta anomalia é realizada a partir alterações macroscópicas na aparência com visualização de áreas pálidas, presença de líquido viscoso e dureza tátil, conforme avaliada a partir da medida por palpação manual dos peitos de frangos (SIHVO et al., 2014). Corresponde à uma medida de natureza subjetiva depende da sensibilidade e conhecimento do analista e, portanto, é suscetível ao erro.

As metodologias para rápida e precisa medição da qualidade dos alimentos são ferramentas necessárias para otimizar as linhas de inspeção industrial (BARBIN et al., 2013). O uso da espectroscopia de infravermelho próximo (NIR) é uma técnica não destrutiva, eficiente e de rápida mensuração das matrizes complexas dos alimentos (ALEXANDRAKIS et al., 2012). É possível analisar e estimar as concentrações dos componentes químicos presentes na carne, tais como lipídios, proteínas, umidade e carboidratos, sendo possível comprovar sua habilidade em predição destes constituintes a partir de modelos de regressão (BARBIN et al., 2013).

A partir do sistema de visão computacional é possível realizar a análise de imagens digitais para gerar um padrão de inspeção da qualidade dos alimentos. Seu uso destaca-se pela simplicidade, baixo custo e o tempo necessário para obtenção dos resultados (BARBIN et al., 2016), apresenta consistência nos dados obtidos e eficiência podendo ser utilizado para inspeção visual de produtos alimentícios (LU et al., 2000).

Desta forma, destaca-se a importância de desenvolver uma técnica objetiva com precisão para verificar a ocorrência e caracterização desta anomalia.

Assim sendo, o objetivo deste trabalho foi identificar e classificar os peitos de frango com a miopatia WB utilizando o Sistema de Visão Computacional (CVS) e informação espectral do infravermelho próximo (NIR) e caracterizar os parâmetros físico-químicos e tecnológicos de peitos de frango normal (N) e WB.

## 2 OBJETIVOS

### 2.1 Objetivo Geral

Identificar e classificar os peitos de frango com a miopatia WB utilizando o Sistema de Visão Computacional (CVS) e informação espectral do infravermelho próximo (NIR) e caracterizar os parâmetros físico-químicos e tecnológicos de peitos de frango normal (N) e WB.

### 2.2 Objetivos Específicos


- Utilizar os algoritmos Máquina de Vetores de Suporte (SVM), Perceptron Multicamadas (MLP), Árvore de Decisão J48 e Floresta Aleatória (RF) do Sistema de Visão Computacional (CVS) para identificar e classificar os peitos de frango em N ou WB.
- Obter informações espectrais por Espectrofotometria de Infravermelho Próximo (NIR) da área cranial dos peitos de frango para classifica-los utilizando a Análise de Componentes Principais (PCA).
- Caracterizar os peitos de frango N e WB por meio de medidas físicas (pH, cor pelo sistema CIELab e textura), químicas (teor de umidade, proteína, lipídios, cinzas) e tecnológicas (capacidade de retenção de água (CRA) e perda de água por cozimento).
- Propor modelos preditivos para identificação e classificação de peitos de frango com a miopatia WB em linhas de abatedouros comerciais.
- Propor uma árvore de decisão utilizando o algoritmo J48 constituída por análises não destrutivas e de rápida mensuração para predizer a classe dos peitos de frango em N ou WB.

### 3 REVISÃO BIBLIOGRÁFICA

#### 3.1 Aspectos Gerais e Características de *Wooden Breast* em Frangos

O primeiro relato sobre *wooden breast* (WB) foi descrito por Sihvo et al. (2014) que corresponde a uma anomalia observada em frangos de corte que afeta o *pectoralis major* muscle e, ocasionalmente, o *pectoralis minor* muscle. É facilmente reconhecido no peito de frango devido à alteração macroscópica no músculo que apresenta uma dureza rígida e palpável. Pode ser observado sob a parte mais espessa do músculo um fluido translúcido, amarelado e viscoso, coloração pálida e, alguns casos, acompanhada por *white striping* (SIHVO et al., 2014). As fotografias dos peitos de frango N e com WB com aparência de abaulamento, dureza palpável, palidez e fluido viscoso de coloração clara são apresentadas na Figura 1.

**Figura 1** – Fotografias de peitos de peitos de frango: (1) Normal; (2) *Wooden breast*.



**Fonte:** Sihvo et al. (2014)

Em geral, as lesões observadas nos peitos de frango WB ocorrem na região superficial dos peitos e estão associadas à fragmentação das fibras musculares e hipoxia muscular com consequente inflamação dos músculos que podem ser observados a partir da histologia e, ainda, na presença de linfócitos T que confirmam a ocorrência do processo inflamatório (MUTRYN et al., 2015; MAZZONI et al., 2015). Os peitos de frango WB apresentaram em quantidades variáveis a distrofia muscular


(degeneração das fibras musculares), de moderada a severa, acúmulo de tecido conjuntivo intersticial (ou fibrose) (KUTTAPPAN et al., 2013; SIHVO et al., 2014; RUSSO et al., 2015;) e de gordura intramuscular (ou lipidose) (TROCINO et al., 2015).

A degeneração das fibras musculares ocasiona mudanças estruturais do músculo, tais como, a redução do conteúdo proteico e aumento da umidade (MAZZONI et al., 2015). Esta anomalia influencia negativamente a aceitação do consumidor devido às alterações na aparência, propriedades tecnológicas e nutritivas (KUTTAPPAN et al., 2012a; MAZZONI et al., 2015; MUDALAL et al., 2015).

Os fatores que podem influenciar à incidência do WB dos frangos de cortes, tais como genótipo, gênero e regime alimentar, desde o nascimento até o abate foram acompanhados e analisados por Trocino et al. (2015). Observaram que apenas o gênero masculino exerceu maior influência na incidência da anomalia e estes frangos apresentaram maior peso final e melhor conversão alimentar quando comparados com as fêmeas. Kawasaki et al. (2016) observaram também que os frangos de cortes (Figura 2) apresentaram diferenças perceptíveis entre as aves N e as afetadas pela anomalia WB.

Segundo Sihvo et al. (2016) os peitos de frango foram avaliados e classificados macroscopicamente como N e WB conforme o grau de severidade (graus de dureza muscular) e localização (focal ou difuso). No peito de frango WB foi observada manifestação focal na região cranial ou caudal, consistência rígida e coloração pálida, enquanto que na manifestação difusa foi observado sob o músculo inteiro e ambas também poderiam apresentar simultaneamente o white striping (WS) (Figura 3). Ainda, foi observado que a incidência da anomalia WB foi influenciada pelo tempo de abate nas idades de 10, 18, 24, 35 e 42 dias. Com 10 dias de idade, não foi verificado a incidência da anomalia, sendo que os primeiros casos foram de ocorrência focal, ou seja, com menor grau de severidade e observados em 28 % do total de aves com 18 dias. Em aves com faixa etária de 24 a 42 dias foi constatado que os WB de frango apresentaram manifestação difusa, ou seja, com grau mais severo. Desta forma, observaram que o WB iniciou focalmente após 10 dias de idade, menor grau de severidade com 18 dias e maior grau de severidade e difusão com idade entre 24 e 42 dias.

**Figura 2** – Posição da ave normal em repouso (figuras a e c) e mantidas com a cabeça acima da coluna vertebral. Posição da ave afetada pelo *Wooden breast* em repouso (figuras b e d) com a coluna vertebral mantida acima da cabeça e as asas abertas para manter o equilíbrio.



**Fonte:** Kawasaki et al. (2016)

**Figura 3** – Peitos de frango: (1) Normal; (2) *Wooden breast* com manifestação focal e (3) *Wooden breast* com manifestação difusa e severa.



**Fonte:** Sihvo et al. (2016)

A expressão dos genes e sequência de RNA dos peitos de frangos N e WB foi investigado por Mutryn et al. (2015) nos quais detectaram a existência de

mais de 1500 genes diferentes em peitos de frango WB. Observaram que os peitos apresentaram hipóxia localizada, estresse oxidativo e calcificação intramuscular. Tais resultados evidenciaram que houve uma superprodução do peptídeo decorina, provocando enrijecimento do músculo devido ao aumento de ligações cruzadas do colágeno (*cross-linking*) (VELLEMAN & CLARK, 2015; ABASHT et al., 2016). Além disto, os peitos de frango com WB apresentaram elevados níveis de histamina, confirmando a ocorrência de processos inflamatórios (ABASHT et al., 2016).


Os peitos de frango WB foram identificados utilizando biomarcadores associados ao estresse oxidativo (ABASHT et al., 2016). Para reduzir a incidência do estresse oxidativo com consequente redução da incidência do WB recomendaram a adição de vitamina C na suplementação dos frangos de linhagem comercial. Ainda, segundo os autores, os peitos com WB apresentaram degeneração muscular, baixos níveis de glicogênio muscular (aproximadamente 1,7 vezes menor quando comparado com peitos de frango N), alterando a taxa de glicose e processos bioquímicos que contribuíram para o enrijecimento dos tecidos musculares dos peitos de frango afetados pela anomalia.

Os peitos de frango WB foram avaliados por Sundekilde et al. (2017) utilizando a espectroscopia de ressonância magnética nuclear (NMR) e observaram que os peitos de frango WB apresentaram maior conteúdo de gordura intracelular. Ainda, foi detectado que os peitos WB apresentaram baixos níveis de carnosina, anserina e creatina no músculo, sendo que a carnosina e anserina (dipeptídeos compostos por  $\beta$ -alanina e histidina), exercem atividades antioxidantes e sua redução contribuiu com a formação do colágeno com ligações cruzadas. Os baixos níveis de creatina das aves afetadas pela anomalia, possivelmente foi devido ao comprometimento das vias geradoras de energia na formação de adenosina trifosfato (ATP).

Os peitos de frango WS são descritos por Kuttappan et al. (2012b) e Kuttappan et al. (2013a) como uma anomalia degenerativa e foram classificados conforme a intensidade que ocorre ao longo do músculo e em três categorias denominadas de normal (sem estriação), moderado (estriação < 1 mm) e severo (estriação > 1 mm) (Figura 4). Sendo que segundo Kuttappan et al. (2013b) os peitos WS apresentaram diferentes níveis de triglicerídeos, colesterol e perfil de ácidos graxos quando comparados com peitos de frango N. A medida que o grau de severidade de peitos de frango WS torna-se significativa ocorre também o aumento e

acúmulo da gordura intramuscular (KUTTAPPAN et al., 2013a; ALNAHHAS et al., 2016). Kuttappan et al. (2013a) avaliaram a incidência de peitos de frango WS e observaram que foi positivamente correlacionada com frangos com maior taxa de crescimento. Esta incidência foi avaliada por meio da visualização das linhas brancas na musculatura do peito da ave e mesma direção das fibras musculares (KUTTAPPAN et al., 2013a).

**Figura 4** – Peitos de frangos *white striping* classificados conforme o grau de severidade: (A) Normal, (B) Moderado e (C) Severo



**Fonte:** Kuttappan et al. (2013a)

Os peitos de frango WS segundo Kuttappan et al. (2013b) foram visualizados a partir da sorologia e hematologia e detectaram que os peitos de frango WS não apresentaram processo inflamatório, enquanto que os peitos de frango WB segundo Sihvo et al. (2014) caracterizaram os WB de frango por histologia das fibras musculares e detectaram a ocorrência do processo inflamatório. Mudalal et al. (2014) observaram que os peitos de frango WB apresentaram maior dano muscular do que os peitos de frango WS e, portanto, propuseram que os peitos de frango WS ocorreram no primeiro estágio da degeneração muscular e a incidência de WB ocorre em estágio mais avançado.

Trocino et al. (2015) descreveram que devido às alterações tecnológicas e de aparência dos peitos de frango WB e WS severo observados em abatedouros, estes peitos são muitas vezes encaminhados para elaboração de produtos derivados. A possibilidade de ocorrência isolada de WB e simultânea de WB

com WS foi investigada por Soglia et al. (2016) no qual observaram que a composição química dos peitos de frango apresentou diferenças significativas. Os peitos de frango com WB e WS analisados por Soglia et al. (2016) apresentaram lesões histológicas severas, com lipidose, fibrose e degeneração das fibras. Além disto, apresentaram maior rigidez nas medidas de textura, maior pH final, menor capacidade de retenção de água, maior umidade e menor valor nutritivo quando comparados com peitos de frango N.

Algumas estratégias podem ser utilizadas para controlar a ocorrência destas anomalias (WB e WS), tais como alimentação de baixa energia e redução da taxa de crescimento (KUTTAPPAN et al., 2012c). Segundo Butzen et al. (2013), o uso da restrição alimentar pode reduzir a taxa de crescimento inicial sem reduzir a qualidade da carne e desempenho dos frangos de cortes. Tais estratégias podem ser interessantes aos produtores e indústrias abatedoras devido à aceitação pelo consumidor e qualidade da carne. Entretanto, podem gerar custos e impactos na economia devido ao maior tempo para alojamento nos aviários para adquirir o ganho de peso ideal para abate e comercialização.

### 3.1 Bioquímica e Composição Química de Carnes

Fatores como a idade, espécie, gênero, restrição alimentar e atividade do animal, tipo de corte, armazenamento e processo de cocção no qual a carne é submetida influenciam diretamente na composição da carne. A composição química da carne de frango é constituída de 74,76 % de água, 23,09 % de proteína, 1,24 % de lipídeos e 1,02 % de cinzas (DAMODARAN et al., 2010).

As fibras musculares individuais das carnes são constituídas por miofibrilas (ESKIN & SHAHIDI, 2015) que são revestidos pelo epimísio. Estes são organizados por um conjunto de feixes que são revestidos pelo perimísio. O conjunto destes feixes musculares são separados pelo tecido conjuntivo denominado de endomísio (BANKS, 1992). No interior das fibras musculares encontra-se o sarcoplasma, sendo constituído por mitocôndria, enzimas, glicogênio, adenosina trifosfato, creatina e mioglobina (ESKIN & SHAHIDI, 2015).

As miofibrilas são responsáveis pelo processo de contração muscular e são separadas pelo retículo sarcoplasmático (ESKIN & SHAHIDI, 2015) e túbulos T (transversos) (COSTANZO, 2014). As miofibrilas contém filamentos grossos e

filamentos finos, dispostos longitudinal e transversalmente denominados de sarcomêros. Os filamentos finos (denominados de linhas A) são constituídos por três proteínas (actina, tropomiosina e tropomina) sensíveis aos íons  $\text{Ca}^{2+}$  as quais participam do processo de contração muscular. Os filamentos grossos são feixes de moléculas de alto peso molecular, sendo que a miosina possui um sítio de ligação de actina e um sítio que se liga ao ATP que é responsável pela sua hidrólise (COSTANZO, 2014).


Após abate do animal, com a instalação do *rigor mortis*, ocorre a perda de sangue (devido à sangria), diminuição das reservas de glicogênio e como consequência, ocorre acúmulo do lactato devido à ausência do sistema circulatório para remoção e queda do pH *post-mortem*. Devido à redução do pH, as enzimas envolvidas no processo da síntese de ATP são inativadas, na ausência de ATP ocorre a formação do complexo químico actomiosina, com contração muscular irreversível, perda de elasticidade e rigidez (ESKIN & SHAHIDI, 2015, RAMOS & GOMIDE, 2017). A instalação do *rigor mortis* em frangos ocorre em aproximadamente uma hora, entretanto, esta duração é influenciada por diversos fatores, tais como, a espécie do animal, aspectos genéticos, reserva inicial de glicogênio, fatores de estresse e temperatura em que ocorre o processo *post-mortem* (DRANSFIELD & SOSNICKI, 1999).

### 3.2 Histologia Muscular dos Peitos de Frango

A seleção genética para obtenção de frangos de cortes de rápido crescimento tem acarretado na formação de fibras musculares com maior seção transversal, na redução do capilar sanguíneo com fornecimento reduzido de sangue, além de diminuir o espaço entre o tecido conjuntivo e fibras musculares que resultam em hipertrofia muscular (DRANSFIELD & SOSNICKI, 1999).

A partir da histologia dos peitos de frango afetadas pela anomalia verificou-se que as fibras musculares apresentaram uma fibrose considerável, sendo esta uma das possíveis causas da rigidez do músculo WB (SIHVO et al., 2014; VELLEMAN & CLARK, 2015). Ainda, além da fibrose, os peitos de frango WB apresentaram fibras musculares com degeneração moderada a severa e variação do diâmetro, inflamação celular e acúmulo de gordura intramuscular (Figura 5) (SIHVO et al., 2014; BROT et al., 2016).

**Figura 5** – Fotografias de peito de frango: (1) Normal; (2) com *Wooden breast* (WB); Histologia do peito de frango: (3) Distribuição das fibras musculares do peito de frango normal com fibras de tamanho uniforme; (4) Distribuição das fibras musculares do peito de frango WB; (5) Fibras musculares degeneradas do peito de frango WB; (6a) Agregação de células mononucleares do peito do frango WB; (6b) Células mononucleares identificadas com o anticorpo CD3 e (7) Tecido conjuntivo do peito de frango em forma compacta e rica em colágeno.



**Fonte:** Sihvo et al. (2014)

### 3.3 Propriedades Funcionais das Carnes

#### 3.3.1 Qualidade da carne

Segundo Becker (2002) a qualidade pode ser definida por meio de medidas subjetivas e objetivas. A primeira corresponde ao atendimento às expectativas do consumidor em relação à segurança, características sensoriais, valores éticos e religiosos, não sendo possível mensurar objetivamente. Enquanto que a segunda corresponde aos atributos mensuráveis de forma objetiva, sendo este o

conceito predominante para a ciência da carne. De acordo com Ramos e Gomide (2017) a qualidade da carne engloba as características da carne como um todo, desde aos aspectos sensoriais até a ausência de anomalias e patógenos.

Os fatores como aparência, aroma, perda por cozimento, maciez, valor nutritivo e propriedades físico-químicas, em particular, o teor de umidade, gordura e proteínas são determinantes para a qualidade e aceitabilidade das carnes (RAMOS & GOMIDE, 2017). Dependendo do teor destes há impactos econômicos devido às implicações tecnológicas e redução das propriedades funcionais e sensoriais. As principais propriedades funcionais da carne, como a textura, capacidade de retenção de água e cor (SHIMOKOMAKI et al., 2006) são prejudicadas em frangos devido à ocorrência de WB (SOGLIA et al., 2016).

### 3.3.2 Aparência

A aparência das carnes é um fator decisivo na compra e aceitabilidade pelo consumidor (RAMOS & GOMIDE, 2017). É a partir da aparência visual que os consumidores selecionam e avaliam a qualidade da carne e seus produtos (QIÃO et al., 2002; PETRACCI & FLETCHER, 2002). Desta forma, a cor é a principal característica do produto e a responsável pela apresentação, sendo determinante para o consumidor na hora da escolha ou compra (SHIMOKOMAKI et al., 2006).

A ocorrência de WB ocasiona mudanças na coloração dos peitos de frango, com observações de regiões com coloração pálida quando comparados com peitos de frango N (SIHVO et al., 2014). Estas alterações provocam aversão perante aos consumidores, visto que, a despigmentação da carne está associada com a perda de frescor e qualidade (MANCINI & HUNT, 2015).

### 3.3.3 pH e capacidade de retenção de água

O pH final das carnes é diretamente influenciado pelo acúmulo do ácido láctico durante a instalação do *rigor mortis* e desempenha papel fundamental na capacidade de retenção de água (CRA) e textura (maciez e suculência). Altos valores de pH estão correlacionados com a coloração escura e baixa perda de água por cozimento, enquanto que baixos valores de pH estão correlacionados com coloração de menor intensidade, baixa capacidade de retenção de água (CRA) e

conseqüentemente com maior perda de água por cozimento (RAMOS & GOMIDE, 2017).

Além disso, a CRA é influenciada por diversos fatores, tais como a idade, espécie e raça do animal (LAWRIE, 2005) e corresponde à capacidade de reter a água que está contida em sua estrutura (SHIMOKOMAKI et al., 2006), durante corte, prensagem, aquecimento e trituração (SARCINELLI et al., 2007) não fluindo no tecido mesmo quando submetido a tais processos. A água retida na matriz alimentícia comporta-se como água pura, sendo facilmente removida no processo de secagem (DAMODARAN et al., 2010). De acordo com Soglia et al. (2016) os peitos de frango com WB possuem menor CRA e afetam diretamente as características sensoriais da carne, tais como cor, textura (SARCINELLI et al., 2007) e suculência, conferindo a carne maior rigidez e baixo valor nutritivo devido à exudação (PARDI et al., 2001). Ainda, a carne que apresenta menor CRA pode perder maior peso durante o armazenamento devido à perda de umidade (SARCINELLI et al., 2007).

#### 3.3.4 Textura

A textura de um alimento corresponde ao conjunto de características geométricas e de superfície que são identificadas por receptores táteis, mecânicos, auditivos e visuais (ABNT, 1993) ou seja, corresponde à resposta do senso tátil ao estímulo físico resultante do contato físico entre o corpo e o alimento (RAMOS & GOMIDE, 2017). Segundo Bourne (2002) que considera os alimentos conforme a aceitação de textura pelo consumidor, estes podem ser divididos em três categorias, sendo como crítica, importante e mínima. A primeira categoria inclui aqueles alimentos cuja a textura foi considerada um fator determinante na qualidade, sendo que a carne se encontra nesta categoria.

Os fatores como raça, gênero, idade, teor de gordura, quantidade de tecido conjuntivo, compactação dos componentes miofibrilares (relacionado ao *rigor mortis* e encurtamento pelo frio) entre outros influenciaram diretamente na maciez da carne (RAMOS & GOMIDE, 2007; RAMOS & GOMIDE, 2017). Os frangos com rápido crescimento apresentaram fibras musculares com maior seção transversal (diâmetro), que por sua vez, poderiam influenciar na textura da carne e conferir maior rigidez. Por exemplo, um frango de rápido crescimento com 55 dias de idade apresentou fibras

com área de 2,755  $\mu\text{m}^2$  enquanto que um frango com crescimento lento com a mesma idade apresentou fibras com área de 1,946  $\mu\text{m}^2$  (DRANSFIELD & SOSNICKI, 1999).

Os peitos de frango WB apresentam maior teor de colágeno (SOGLIA et al., 2016), sendo este outro fator determinante na textura da carne. Um animal mais jovem possui maior concentração de colágeno em seu músculo, entretanto, devido às ligações peptídicas serem lábeis ao calor, a carne torna-se mais macia quando comparada com os animais mais velhos (LAWRIE, 2005). A medida que a ave envelhece, a solubilidade do colágeno diminui, aumentando o conteúdo de piridinolina (PYR) e força de cisalhamento devido ao aumento do número de ligações cruzadas (CORÓ et al., 2002). O aumento do número de ligações cruzadas intermoleculares do colágeno aumentou a estabilidade e resistência ao calor, influenciando diretamente na textura da carne (LIGHT et al., 1985). O rápido crescimento das aves proporciona um aumento na síntese de colágeno e consequente diminuição de ligações cruzadas, tornando a carne mais macia (CORÓ et al., 2002), porém, o rápido crescimento dos frangos poderia ser uma das possíveis causas da ocorrência de WB.

### 3.4 Espectroscopia de Infravermelho Próximo (NIR) e Análise de Imagem Digital

As metodologias para rápida e precisa medição da qualidade dos alimentos são ferramentas necessárias para otimizar as linhas de inspeção industrial (BARBIN et al., 2013). O uso da espectroscopia de infravermelho próximo (NIR) é uma técnica não destrutiva, eficiente e de rápida mensuração das matrizes complexas dos alimentos (ALEXANDRAKIS et al., 2012). É possível analisar e estimar as concentrações dos componentes químicos presentes na carne, tais como lipídios, proteínas, umidade e carboidratos, sendo possível comprovar sua habilidade em predição destes constituintes a partir de modelos de regressão (BARBIN et al., 2013).

O espectrofotômetro pode fornecer informações devido às vibrações das combinações e ligações das moléculas, tais como C-H, O-H e N-H nos comprimentos de ondas de 1.100 a 1400 nm, 1.450 nm e 1.460 a 1.570 nm, respectivamente, abrangendo uma diversidade de componentes químicos presentes nos alimentos (MURRAY & WILLIAMS, 1987; SHENK et al., 1992; ALEXANDRAKIS et al., 2012). Permite a mensuração simultânea de diversos componentes alimentícios (PREVOLNIK et al., 2011). A espectroscopia possibilita a caracterização dos constituintes das matrizes alimentícias por meio da extração das informações de

amostras heterogêneas (GOWEN et al., 2008; RAVN et al., 2008) e a carne é altamente heterogênea devido a diferença das fibras musculares e características físicas e químicas (BARLOCCO et al., 2006).

O NIR tem despertado interesses por ser uma alternativa aos métodos convencionais que normalmente são mais demorados e necessitam de componentes altamente prejudiciais ao meio ambiente e ao analista, como por exemplo, a utilização de solventes orgânicos para determinação de lipídios nos alimentos (PREVOLNIK et al., 2011).

Devido à heterogeneidade da superfície da carne ocasionada pela presença de fibras musculares, tecido conjuntivo e gordura intramuscular (BARLOCCO et al., 2006), a aquisição de imagens, tratamento e análise tem despertado interesses por possibilitar a verificação de uma área superficial maior do que a abrangida pelo do colorímetro. A análise de imagens destaca-se pela simplicidade, baixo custo e o tempo necessário para obtenção dos resultados (BARBIN et al., 2016), apresenta consistência nos dados obtidos e eficiência podendo ser utilizado para inspeção visual de produtos alimentícios (LU et al., 2000).

Ressalta-se que o uso do NIR e obtenção de imagens digitais de peitos de frango com WB com finalidade de classificação e predição ainda não foi descrita.

### 3.5 Árvore de Decisão

Para classificação e predição de um conjunto de dados selecionados com atributos de maior ganho de informação (LAST & ROIZMAN, 2013) tem sido utilizado a árvore de decisão como um método estatístico de fácil implementação (RUSSEL & NORVIG, 2004) e fácil interpretação (DUDA et al., 2001). Na árvore de decisão, o atributo selecionado para iniciar uma classificação e predição de amostras é denominado de raiz (localizado no topo da árvore), os atributos localizados abaixo da raiz recebem a denominação de nó (DUDA et al., 2001), os valores para tomada de decisão são denominados de ramos e as classes recebem a denominação de folhas (GAMA, 2004).

Para iniciar a classificação das amostras, o algoritmo estabelece um determinado valor para o atributo raiz e a partir deste, ocorre uma divisão binária para predição, ou seja, aqueles que possuem valor maior que o limiar e aqueles que

possuem valor menor ou igual ao limiar estabelecido pelo algoritmo. De acordo com o valor correspondente ao atributo, há a possibilidade de obtenção da classe de imediato, ou ainda, prosseguir com os testes referentes aos atributos subsequentes até obter a classificação e predição apropriada à amostra (DUDA et al., 2001).

Dentre os algoritmos utilizados para indução da árvore de decisão, está o algoritmo J48. Este algoritmo testa um único atributo em cada nó de acordo com o ganho de informação e executa uma validação cruzada do método a partir dos dados de treinamento, executando uma sequência de testes (MOHANTY et al., 2010). Na validação cruzada, os dados informados para treinamento do modelo preditor são compartilhados para testá-lo e o desempenho final é obtido pela média dos desempenhos de cada teste executado (BRAGA et al., 2000).

A avicultura brasileira tem grande importância mundial, sendo o peito de frango um dos cortes de maior impacto econômico devido à sua proporção e peso. A ocorrência da miopatia WB compromete a qualidade e aceitabilidade do peito de frango ofertado. Desta forma, destacam-se a importância e necessidade de caracterizar os peitos de frangos WB e desenvolver métodos rápidos e não destrutivos com o uso de NIR e CVS para identificar e classificar estes peitos em uma linha de abatedouro avícola visto que ainda não há o emprego destas técnicas de análises para esta finalidade. A aplicação prática do método na inspeção de corte ainda na linha de produção, possibilitará obter resultados rápidos e eficientes, e ainda, poderá tornar-se fonte de referência e pesquisa, instigando a estudos posteriores que desvendem a etiologia da miopatia.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ABASHT, B.; MUTRYN, M. F.; MICHALEK, R. D.; LEE, W.R. Oxidative stress and metabolic perturbations in *Wooden breast* disorder in chickens. **PLoS ONE**, v.11, n. 4, p. 1-17, 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 Bioprocess Technology**, v. 5, n.1, p. 338-347, 2012.
- ALNAHHAS, N.; BERRI, C.B; CHABAULT, M.; CHARTRIN, P.; BOULAY, M.; BOURIN, M.C.; BIHAN-DUVAL, E.L. Genetic parameters of white striping in relation to body weight, carcass composition, and meat quality traits in two broiler lines divergently selected for the ultimate pH of the pectoralis major muscle. **BMC genetics**, v. 17, n. 1, p. 61, 2016.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. Análise sensorial dos alimentos e bebidas: terminologia. 1993. 8 p
- Associação Brasileira de Proteína Animal (ABPA). Avicultura – Relatório Anual. São Paulo, 2016. Disponível em: < <http://abpa-br.com.br/setores/avicultura/mercado-mundial/frango>>. Acesso em agosto de 2017.
- BANKS, W.J. **Histologia veterinária aplicada**. 2.ed. São Paulo: Manole Ltda., 1992. 655 p.
- BARBIN, D.F.; ELMASRY, G.; SUN, D, ALLEN, P. Non-destructive determination of chemical composition in intact and minced pork using near-infrared hyperspectral imaging. **Food Chemistry**, v.138, n. 2, p. 1162–1171, 2013.
- BARBIN, D.F.; MASTELINI, S.M.; BARBON-JÚNIOR, S.;CAMPOS, G.F.C; BARBON, A.C.; SHIMOKOMAKI, M. Digital image analyses as an alternative tool for chicken quality assessment. **Biosystems Engineering**, v.144, p.85-93, 2016.
- BARLOCCO, N.; VADELL, A.; BALLESTEROS, F.; GALIETTA, G.; COZZOLINO, D. Predicting intramuscular fat, moisture and Warner-Bratzler shear force in pork muscle using near infrared reflectance spectroscopy. **Animal Science**, v.82, n. 1, p. 111-116.
- BECKER, T. Defining meat quality. **Meat processing: improving quality**. New York: CRC Press, 2002. 451 p.
- BOURNE, M. C. **Food texture and viscosity: concept and measurement**. 2. ed. Academic Press: London, 2002, 416 p.
- BRAGA, A.D.P.; CARVALHO, A.C.P.L.F.; LUDEMIR, T.B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: Livros Técnicos e Científicos, 2000.

BROT, S.; PEREZ, S.; SHIVAPRASAD, H.L.; BAIKER, L.; POLLEDO, L.; CLARK, M.; GRAU-ROMA, L. *Wooden breast* lesions in broiler chickens in the UK. **Veterinary Record**, 178:141, 2016.

BUTZEN, F.M.; RIBEIRO, A.M.L.; VIEIRA, M.M.; KESSLER, A.M.; DADALT, J.C.; DELLA, M.P. Early feed restriction in broilers. I—Performance, body fraction weights, and meat quality. **Poultry Science Association**, v. 22, n. 02, p. 251-259, 2013.

CORÓ, F. A.G.; YOUSSEF, E.Y., SHIMOKOMAKI, M. Age related changes in poultry breast meat collagen pyridinoline and texture. **Journal of food biochemistry**, v. 26, n. 6, p. 533-554, 2002.

COSTANZO, L. **Fisiologia**. 5. ed. Rio de Janeiro: Elsevier, 2014.

DAMODARAN, S.; PARKIN, K.L.; FENNEMA, O.R. **Química de Alimentos**, 4. ed. Porto Alegre: Artmed, 2010.

DRANSFIELD, E.; SOSNICKI, A. A. Relationship Between Muscle Growth and Poultry Meat Quality. **Poultry Science**, v. 78, n. 5, p. 743–746, 1999.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. John Wiley and Sons, 2001.

ESKIN, M.; SHAHIDI, F. **Bioquímica de alimentos**. 3. ed. Rio de Janeiro: Campus Elsevier, 2015. 536 p.

GAMA, J. A. Functional trees. **Machine Learning**, v. 55, n. 3, p. 219–250, 2004.

GOWEN, A.A.; O'DONELL, C.P. CULLEN, P.J.; BELL, S.E.J. Recent application of chemical imaging to pharmaceutical process monitoring and quality control. **European Journal of Pharmaceutics and Biopharmaceutics**, n.69, n. 1, p. 10-22, 2008.

HAVENSTEIN, G.B.; FERKET, P.R.; QURESHI, M.A. Carcass Composition and Yield of 1957 Versus 2001 Broilers When Fed Representative 1957 and 2001 Broiler Diets. **Poultry Science**, n. 82, n.10, p. 1509–1518, 2003.

JUNQUEIRA, L. C.; CARNEIRO, J. **Histologia Básica**, Guanabara Koogan, 2004.

KAWASAKI, T.; TAKASHI, Y.; WATANABE, T. Simple method for screening the affected birds with remarkably hardened pectoralis major muscles among broiler chickens. **Journal of Poultry Science**, v. 53, n. 4, p. 291-297, 2016.

KUTTAPPAN, V.A.; LEE, Y.S.; ERF, G.F.; MEULLENET, J.F.C.; MCKEE, S.R.; OWENS, C.M. Consumer acceptance of visual appearance of broiler breast meat with varying degrees of white striping. **Poultry Science**, v. 91, n. 5, p. 1240–1247, 2012a.

KUTTAPPAN, V. A.; BREWER, V.B.; APPLE, K.; WALDROUP, W.; OWENS, C.M. Influence of growth rate on the occurrence of white striping in broiler breast fillets. **Poultry Science**, v. 91, n.10, p. 2677–2685, 2012b.

KUTTAPPAN, V.A.; GOODGAME, S.D.; BRADLEY, C.D.; MAUROMOUSTAKOS, A.; HARGIS, B.M.; WALDROUP, P.W.; OWENS, C. Effect of different levels of dietary vitamin E (DL –  $\alpha$  – tocopherol acetate) on the occurrence of various degrees of white striping on broiler breast fillets. **Poultry Science**, v. 91, n. 12, p. 3230–3235, 2012c.

KUTTAPPAN, V.A.; SHIVAPRASAD, H.; SHAW, D.P.; VALENTINE, B.A.; HARGIS, B.M.; CLARK, F.D.; Pathological changes associated with white striping in broiler breast muscles. **Poultry Science**, v. 92, n.2, p. 331-338, 2013a.

KUTTAPPAN, V.A.; HUFF, G.R.; HUFF, W.E.; HARGIS, B.M.; APPLE, J.K.; COON, C.; OWENS, C.M. Comparison of hematologic and serologic profiles of broiler birds with normal and severe degrees of white striping in breast fillets. **Poultry Science**, v. 92, n. 2, p.339–345, 2013b.

LAST, M.; ROIZMAN, M.; Avoiding the Look-Ahead Pathology of Decision Tree Learning. **International Journal of Intelligent Systems**, v. 28, n. 10, p. 974-987, 2013.

LAWRIE, R.A. **Ciência da carne**. 6<sup>o</sup> ed. Porto Alegre: ARTMED, 2005. 384p.

LIGHT, N.; CHAMPION, A.E.; VOYLE, C.; BAILEY, A.J. The role of epimysial, perimysial and endomysial collagen in determining texture in six bovine muscles. **Meat Science**, n.13, n.3, p. 137-149, 1985.

LU, J.; TAN, J.; SHATADAL, P.; GERRARD, D.E. Evaluation of pork color by using computer vision. **Meat Science**, n. 56, n.1, p. 57-60, 2000.

MANCINI, R.A.; HUNT, M.C. Current research in meat color. **Meat Science**, v. 71, n. 1, p. 100-121, 2005.

MAZZONI, M.; PETRACCI, M.; MELUZZI, A.; CAVANI, C.; CLAVENZANI, P.; SIRRI, F. Relationship between pectoralis major muscle histology and quality traits of chicken meat. **Poultry Science**, v. 94, n.1, p. 123– 130, 2015.

MOHANTY, R.; RAVI, V.; PATRA, M.R. Web-services classification using intelligent techniques. **Expert Systems with Applications**, v. 37, n. 7, p. 5484-5490, 2010.

MUDALAL, S.; BARBINI, E.; CAVANI, C.; PETRACCI, M. Quantity and functionality of protein fractions in chicken breast fillets affected by white striping. **Poultry science**, v. 93, n. 8, p. 2108-2116, 2014.

MUDALAL, S.; LORENZI, M.; SOGLIA, F.; CAVANI, C.; PETRACCI, M. Implications of white striping and *wooden breast* abnormalities on quality traits of raw and marinated chicken meat. **Animal**, v. 9, n. 4, p. 728–734, 2015.

MURRAY, I.; WILLIAMS, P. C.; NORRIS, Karl. Near-infrared technology in the agricultural and food industries. **American Association of Cereal Chemists**, St Paul, MN: American Association of Cereal Chemists, 1987.

MUTRYN, M. F.; BRANNICK, E. M.; FU, W.; LEE, W. R.; ABASHT, B. Characterization of a novel chicken muscle disorder through differential gene

expression and pathway analysis using RNA-sequencing. **BMC Genomics**, v.16, n.1, p. 399, 2015.

PARDI, M.C.; SANTOS, I.F.; SOUZA, E.R. **Ciência, higiene e tecnologia da carne**. 2.ed. Goiânia: UFG, 2001.

PETRACCI, M.; FLETCHER, D.L. Broiler Skin and Meat Color Changes During Storage. **Poultry Science**, n. 81, n.10, p. 1589–1597, 2002.

PETRACCI, M.; MUDALAL, S.; SOGLIA, F.; CAVANI, C. Meat quality in fast-growing broiler chickens. **Word's Poultry Science Journal**, v. 71, n. 2, p. 363-374, 2015.

PREVOLNIK, M.; SKRLEP, M.; JANES, L.; VELIKONJA-BOLTA, S.; SKORJANC, D.; CANDEK-POTOKAR, M. Accuracy of near infrared spectroscopy for prediction of chemical composition, salt content and free amino acids in dry-cured ham. **Meat Science**, n. 88, n. 2, p. 299-304, 2011.

QIÃO, M.; FLETCHER, D.L.; NORTHCUTT, J.K. SMITH, D.P. The Relationship Between Raw Broiler Breast Meat Color and Composition. **Poultry Science**, v. 81, n.3, p. 422–427, 2002.

RAMOS, E.M.; GOMIDE, L.A.M. **Avaliação da qualidade de carnes – Fundamentos e metodologias**: Textura e maciez da carne. Viçosa: UFV, 2007.

RAMOS, E.M.; GOMIDE, L.A.M. **Avaliação da qualidade de carnes – Fundamentos e metodologias**: Textura e maciez da carne. Viçosa: UFV, 2017.

RANDALL, D.; BURGGREN, W.; ECKERT, F. K. **Fisiologia Animal: Mecanismos e Adaptações**. 4.ed. Rio de Janeiro: Guanabara Koogan, 2000.

RAVN, C.; SHIBSTED, E.; BRO, R. Near-infrared chemical imaging (NIR-CI) on pharmaceutical solid dosage forms-comparing common calibrations approaches. **Journal of Pharmaceutical and Biomedical Analysis**, v.48, n. 3, p. 554-561, 2008.

RUSSELL, S.; NORVIG, P. INTELLIGENCE, Artificial. A modern approach. **Artificial Intelligence**. Prentice-Hall, Englewood Cliffs, v. 25, p. 27, 1995.

RUSSO, E.; DRIGO, M.; LONGONI, C.; Evaluation of White Striping prevalence and predisposing factors in broilers at slaughter. **Poultry Science**, v. 94, p. 1843–1848, 2015.

SARCINELLI, M. F.; SILVA, L. C.; VENTURINI, K. S. **Características da Carne Suína**. Universidade Federal do Espírito Santo – UFES, 2007. 7p. (Boletim Técnico, PIE – UFES:00907).

SHENK, J.S.; WESTERHAUS, M.O.; WORKMAN, J.J. **Handbook of Near Infrared Analysis, Practical Spectroscopy Series**: Application of NIR spectroscopy to agricultural products. 2 ed. New York: Marcel Dekker, 1992.

SHIMOKOMAKI, M.; OLIVO, R.; TERRA, N. N.; FRANCO, B. D. G. M **Atualidades em Ciência e Tecnologia de Carnes**. 1. ed., São Paulo: Varela, 2006.

- SIHVO, H. K.; IMMONEN, K.; PUOLANNE, E. Myodegeneration with fibrosis and regeneration in the pectoralis major muscle of broilers. **Veterinary Pathology**, v. 51, n.3, p. 619-623, 2014.
- SIHVO, H.K.; LINDÉN, J.; AIRAS, N.; IMMONEN, K.; VALAJA, J.; PUOLANNE, E. *Wooden breast* Myodegeneration of Pectoralis Major Muscle Over the Growth Period in Broilers. **Veterinary Pathology**, v.54, n.1, p. 119-128, 2016.
- SOGLIA, F.; MUDALAL, S.; BARBINI, E.; DI NUNZIO, M.; MAZZONI, M.; SIRRI, F.; CAVANI, C. PETRACCI, M. Histology, composition, and quality traits of chicken Pectoralis major muscle affected by *wooden breast* abnormality. **Poultry Science**, v. 95, n. 3, p. 651-659, 2016.
- SUNDEKILDE, U.K; RASMUSSEN, M.K.; YOUNG, J. F.; BERTRAM, H.C. High resolution magic angle spinning NMR spectroscopy reveals that pectoralis muscle dystrophy in chicken is associated with reduced muscle content of anserine and carnosine. **Food Chemistry**, v. 217, p. 151-154, 2017.
- TROCINO, A.; PICCIRILLO, A.; BIROLO, M.; RADAELLI, G.; BERTOTTO, D.; FILIOU, E.; PETRACCI, E.; XICCATO, G. Effect of genotype, gender and feed restriction on growth, meat quality and the occurrence of white striping and *wooden breast* in broiler chickens. **Poultry Science**, v. 94, n. 12, p. 2996 – 3004, 2015.
- VALCESCHINI, E. Poultry meat trends and consumer attitudes. In Proceedings of the XII European Poultry Conference. Verona, Italy, 2006. CD-ROM.
- VELLEMAN, S.G.; CLARK, D.L. Histopathologic and Myogenic Gene Expression Changes Associated with *Wooden breast* in Broiler Breast Muscles. **American Association of Avian Pathologists**, v. 59, n. 3, p. 410 – 418, 2015.

#### **4 MATERIAL E MÉTODOS**

O item MATERIAL E MÉTODOS será contemplado na descrição do Artigo Científico intitulado “Rapid Identification and Classification of Wooden Breast in Chicken by Computer Vision and Near-Infrared Spectroscopy, and Physicochemical and Technological Characterization” e submetido para publicação em um periódico científico da área de Ciência de Alimentos.

## **5 RESULTADOS E DISCUSSÃO**

O item RESULTADOS E DISCUSSÃO será contemplado na descrição do Artigo Científico intitulado "Rapid Identification and Classification of Wooden Breast in Chicken by Computer Vision and Near-Infrared Spectroscopy, and Physicochemical and Technological Characterization" e submetido para publicação em um periódico científico da área de Ciência de Alimentos.

## 1 5.1 Artigo Científico

2 **Rapid Identification and Classification of Wooden Breast in Chicken by a**  
3 **Computer Vision System and Near-Infrared Spectroscopy, and**  
4 **Physicochemical and Technological Characterization**

5

6 Bruna Caroline Geronimo<sup>1</sup>, Saulo Martiello Mastelini<sup>2</sup>, Rafael Humberto de  
7 Carvalho<sup>1</sup>, Sylvio Barbon Júnior<sup>2</sup>, Douglas Fernandes Barbin<sup>3</sup>, Massami  
8 Shimokomaki<sup>4</sup>, Elza louko Ida<sup>1</sup>

9

10 **Affiliations**11 <sup>1</sup> Department of Food Science and Technology, State University of Londrina  
12 (UEL), Brazil13 <sup>2</sup> Department of Computer Science, State University of Londrina (UEL), Brazil14 <sup>3</sup> Department of Food Engineer, State University of Campinas (UNICAMP), Brazil15 <sup>4</sup> Department of Animal Science, State University of Londrina (UEL), Brazil

16

17 Elza louko Ida

18 Phone: +55 43 3371 5971; fax: +55 43 3371 4080

19 elida@uel.br

20

21 **Abstract** The aim of this study was to identify and classify chicken breasts with wooden  
22 breast (WB) myopathy using a computer vision system (CVS) and spectral information  
23 from the near infrared (NIR) spectroscopy to characterize the physicochemical and  
24 technological parameters of normal (N) and WB of chicken. A total of 80 *pectoralis*

25 *major* muscle samples were collected from a commercial poultry slaughterhouse, with  
26 40 of each type. Spectral information was obtained by CVS and NIR. N and WB of  
27 chickens were characterized by physicochemical and technological measurements.  
28 Combining image analyses with a support vector machine (SVM) classification model  
29 using intensity and textural image features extracted from pictures of chicken breast,  
30 91.83% of chicken breasts were correctly classified as N or WB. In comparison, the  
31 use of NIR spectral information showed 97.5% of accuracy. Regarding the  
32 physicochemical and technological characteristics, WB of chicken showed increases  
33 of 2.21% and 106.67% in moisture and lipid contents and decreases of 14.41% and  
34 13.04% in protein and ash contents, respectively. In addition, WB showed 9.96%,  
35 64.19%, and 23.28% increased values for  $L^*$ ,  $a^*$ , and  $b^*$ , respectively; 1.91% for pH,  
36 and 106.06% for water holding capacity. The shear force of raw WB of chicken was  
37 49.51% hardness, and after cooking was 31.79% softer than N chicken breast. CVS  
38 and NIR spectroscopy can be applied as a rapid and non-destructive methods for  
39 identifying and classifying WB of chickens in slaughterhouses.

40

41 **Keywords** Algorithms. Broilers. Hyperspectral Image. Image processing. Machine  
42 Learning.

43

## 44 **Introduction**

45

46 In recent years, the occurrence of wooden breast (WB) in broilers has been reported  
47 and is associated with the rapid growth and development of breasts, but its etiology  
48 remains unclear (Sihvo et al. 2014; Mudalal et al. 2015; Mutryn et al. 2015). To meet  
49 the growing demand for chicken meat, mainly from western countries, genetic

50 improvement is used as an important solution for the poultry industry to obtain high-  
51 yielding broilers (Fletcher 2004; Petracci et al. 2015). However, this has led to an  
52 increased incidence of chicken breast myopathy in Europe, the USA, and Brazil and is  
53 associated with the rapid growth and development of chicken breast (Kuttappan et al.  
54 2012; Sihvo et al. 2014; Mudalal et al. 2015; Mutryn et al. 2015).

55           WB is characterized by reduced meat quality related to undesirable changes  
56 in visual aspects, technological characteristics, and nutritive properties (Sihvo et al.  
57 2014; Trocino et al. 2015; Soglia et al. 2016; Mazzoni et al. 2015). Chicken breast  
58 affected by WB myopathy shows substantial hardness, pale areas, and superficial  
59 viscous fluid and can be accompanied by white striping (WS) (Sihvo et al. 2014). In  
60 addition, the breast shows alterations in chemical and technological characteristics,  
61 such as increased moisture and lipid contents and reduced protein content and water  
62 holding capacity (Mudalal et al. 2014; Sihvo et al. 2014; Mazzoni et al. 2015; Trocino  
63 et al. 2015; Soglia et al. 2016). The identification and characterization of WB in broilers  
64 at the slaughterhouse are based on visible appearance and hardness of chicken breast  
65 (Sihvo et al. 2014) and depend on the sensitivity, training, and knowledge of the  
66 analyst.

67           The use of rapid, non-destructive, and accurate analytical methods in food  
68 quality inspection has increased among industry professionals seeking to optimize  
69 quality inspection lines and reduce measurement time and costs. These methods  
70 include near-infrared spectroscopy (NIR) and digital image analysis. NIR corresponds  
71 to a nondestructive, efficient, and rapid technique for measuring complex food matrices  
72 such as moisture, carbohydrate, lipid, and protein contents from regression models  
73 (Alexandrakis et al. 2012; Barbin et al. 2013).

74 Previous studies have reported the successful use of NIR spectral  
75 information for predicting quality through rapid and simultaneous determination of food  
76 components (Ignat et al. 2014; Ye et al. 2014), particularly in chicken breast (Barbin et  
77 al. 2015; Wold et al. 2017). The use of NIR is an alternative to conventional analytical  
78 methods, which generally require chemicals that are harmful to the environment and  
79 analysts, such as the use of organic solvents to extract lipids (Prevolnik et al. 2011).  
80 In contrast, digital image analysis solutions have been widely employed because of  
81 their flexibility, simplicity, low-cost, and reduced processing time. An example of this  
82 flexibility was explored in Barbin et al. (2016) through automatic broiler breast color  
83 measurements in larger and trustful areas in contrast of colorimeter. NIR-based  
84 analysis involves large groups of tones and combination bands related to desired  
85 response information (Porep et al. 2015). Commonly, multivariate analysis is used to  
86 extract information from NIR, which can also be employed for modeling the studied  
87 problem. This model evaluates characteristics extracted from a sample based on its  
88 spectral properties and can be used to predict new samples using the project system  
89 (Galasso et al. 2017).

90 A computer vision system (CVS) is a computing implementation of an  
91 automate image analysis solution for sample analysis from the acquisition to decision  
92 step. Sun (2016) described CVS as a fast, robust, objective, non-destructive, and  
93 reliable method, and may be a low-cost alternative for laboratory analysis. In some  
94 applications, it is possible to simulate the human technician's visual inspection using a  
95 CVS (Sun 2016). Features extracted from images are often used for classification and  
96 prediction models to identify samples from different classes or predict quality  
97 parameters. Some approaches include linear methods and non-linear machine

98 learning algorithms, such as SVM, multilayer perceptron (MLP), decision trees, and  
99 random forest (RF) (Campos et al. 2016).

100 Therefore, considering the impact of WB myopathy on the quality and  
101 acceptability of chicken breast, the aim of this study was to identify and classify chicken  
102 breasts with WB using a CVS and spectral information from the NIR region by using  
103 linear and nonlinear algorithms and characterize the physicochemical and  
104 technological parameters of N and WB of chickens.

105

## 106 **Material and Methods**

107

### 108 **Chicken Breast Selection**

109

110 Eighty *pectoralis major* muscle samples were obtained from a commercial processing  
111 plant located in the state of Paraná, Brazil. Broilers from a single flock of Cobb fast (48  
112 days of age and 3.1 kg live weight) were slaughtered according to standard commercial  
113 slaughtering practice, including electrically stunning, bleeding, scalding, defeathering,  
114 evisceration, cooling, and deboning. Chicken breasts were selected by an expert as N  
115 (n = 40) and WB (n = 40) as described by Sihvo et al. (2014). Normal breasts presented  
116 soft and palish pink characteristics and WB were identified by manual palpation with  
117 substantial hardness, visual appearance on the surface, and accompanied by viscous  
118 material and pale areas. The samples were placed in separate plastic bags and  
119 transported under refrigeration to the laboratory. After acquiring image information  
120 using a CVS and NIR, chicken breasts were stored at 4 °C to determine the  
121 physicochemical and technological parameters.

122 Computer Vision System

123

124 An image acquisition system model Doc L-Pix (Loccus Biotecnologia, São Paulo,  
125 Brazil) was used to acquire images of N and WB of chicken. The equipment consists  
126 of a standard illumination and image acquisition system controlled by L-PIX IMAGE  
127 7.1 software. Images were stored with 1600x1200 pixels in png format. Overview of  
128 the proposed CVS is presented in Fig. 1.

129

130 *Image Acquisition and Segmentation*

131

132 After image acquisition, the meat portion was segmented from the background (Step  
133 1). Image segmentation steps are presented in Fig. 2. Contrast enhancement was  
134 applied to the segmented region to accentuate the visual texture aspects typically  
135 present in WB of chicken. Image features were extracted from the processed image  
136 (Step 2) and used to describe the occurrence or non-occurrence of WB myopathy by  
137 applying a machine learning model (Step 3).

138 For chicken breast segmentation, we applied illumination normalization (Step (2) in  
139 Fig. 2), as described by Barbin et al. (2016), to attenuate the effect of incident light  
140 spots. This technique uses a combination of the original image's brightness information  
141 combined and its reverse intensity representation to mitigate the visual effect of  
142 incident spotlights. Next, the difference between V and H channels from hue,  
143 saturation, and value (HSV) images was used to separate the sample from the  
144 background. Pixels not related to the sample were removed from the image. A

145 threshold was established to create a mask for segmentation of the sample from the  
146 background using Otsu's thresholding.

147 The operation resulted in a rough binary meat mask, representing the region of interest  
148 (ROI) (Fig. 2, Step (5)). At the end of Step (6), a morphological erode operation was  
149 performed to separate small connected regions, such as undesired ruler's contours. A  
150 small connected regions removal algorithm (Step (7)) was used to eliminate possible  
151 remaining noisy areas.

152

### 153 *Contrast Enhancement and Feature Extraction*

154

155 The normalized, segmented, and filled images were subjected to the contrast limited  
156 adaptive histogram equalization (CLAHE) (Zuiderveld 1994), as shown in Fig. 2, Step  
157 (9). This technique was performed to increase the contrast between the meat region  
158 and the visual appearance of WB myopathy. The CLAHE technique uses two  
159 parameters: window size, corresponding to the length of blocks that subdivide the  
160 image for equalization, and clip limit, which determines a limit for contrast  
161 enhancement. For images with 1600 × 1200 resolution, we suggest a window size of  
162 [64, 64] and clip limit of 0.07.

163 Features extracted from images provide useful information for automatic classification  
164 as described by Nixon and Aguado (2012) and can be used to describe the visual  
165 appearance of chicken breast to differentiate N and WB of chicken. In this study, we  
166 used features from two groups: intensity and texture.

167 The color information of an image follows a probability distribution as described by Li  
168 et al. (2015). Thus, their distribution moments were used as image features for  
169 classification. Grayscale metrics were chosen to explain the occurrence of WB, as the

170 output from the presented image processing framework corresponded to an improved  
171 grayscale enhanced image. In this manner, the moments of the color of the first and  
172 second order (mean and standard deviation) were extracted directly from the intensity  
173 representation. We also calculated entropy, a statistical measure of randomness, to  
174 characterize the texture and contrast of the grayscale image (Gonzalez and Woods  
175 2010; Balaji et al. 2015; Campos et al. 2016a). Furthermore, from the histogram  
176 (frequency distribution of pixels values), we extracted the standard deviation, kurtosis,  
177 and skewness values (second, third, and fourth statistical moments).

178 Texture features are important characteristics used to identify visual repetition patterns  
179 (such as WB striations), objects, or regions of interest in an image and are applied in  
180 a wide variety of image classification (Haralick et al. 1973). Local binary patterns (LBP)  
181 were used as a texture descriptor of local images (Ojala et al. 2002). It encodes the  
182 local texture in a binary vector by comparing a grayscale pixel and its neighbors. We  
183 adopted 10 values from the rotationally invariant features of LBP (Ojala et al. 2002).  
184 Table 1 summarizes all image features used to build the supervised classification  
185 models.

186

### 187 *Identification and Classification Approaches of N and WB of Chickens*

188

189 A supervised machine learning algorithm was used to classify chicken breasts into N  
190 and WB categories. A machine learning model learns how to associate meat surface  
191 visual aspects with a categorical response, and can then be applied to predict new  
192 samples. A total of four classification approaches were evaluated in this study. Our  
193 choice was based on evaluating techniques belonging to algorithms in different families  
194 and their wide use in different classification tasks. Thus, the experiments were

195 performed using SVM, MLP artificial neural network, J48 decision tree, and RF  
196 ensemble classifier method.

197 SVM is a machine learning algorithm proposed by Vapnik (1995). SVM belongs to the  
198 class of kernel based methods, for which the main idea relies on finding a hyperplane  
199 that best separates a problem's classes. SVMs are highly flexible for evaluating  
200 multiple types of problems (Papadopoulou et al. 2013; Deka and Raghavendra 2014;  
201 Sun 2016) and were originally used for binary classification tasks. In our experiments,  
202 the e1071 R package for SVMs induction was used.

203 Another frequently applied algorithm is MLP feed forward networks, an important class  
204 of artificial neural networks (ANN) (Livingstone 2008). ANN simulate brain synapses  
205 and knowledge learning using linear and non-linear relationships (Sun 2016). The  
206 RSNNS R package was utilized for MLP computation.

207 Considering its simplicity, the J48 algorithm, a decision tree technique and version of  
208 the C4.5 technique (Quinlan 1993), was developed by Weka software (Hall et al. 2009).  
209 The classification model is built by successive partition of input space into smaller  
210 problems. A wrapper for Weka J48 implementation was employed in our experiments  
211 using the RWeka package.

212 The RF method is an ensemble learning approach proposed by Breiman (2001). The  
213 term ensemble refers to the combination of many simple, or weak, learners in a set, in  
214 RF case, to combine many decision trees into a forest, naming the technique. The  
215 randomForest R package was used in this study.

216 Each described classification model was performed 50 times using different training  
217 and testing dataset configurations. A holdout approach with 70% of the dataset was  
218 used for training. To evaluate the performance of the classification models, accuracy  
219 and F-measure were used. Accuracy refers to overall system performance and is

220 defined as the number of instances correctly classified among all cases. The F-score  
221 is defined as the harmonic mean between precision and recall. Precision is defined as  
222 the rate of true positives of a class X, among all instances classified as X. It shows the  
223 class agreement of data labels with positive labels predicted by a trained classifier.  
224 Recall or sensitivity measures the effectiveness of a classifier to identify positive labels  
225 (i.e., problem's classes). For each class, recall is defined as the number of true positive  
226 predicted cases divided by the number of instances belonging to the referred class.  
227 We used weights equal to one for both precision and recall in F-measure calculation.

228

## 229 Decision Tree

230

231 The decision tree corresponds to a flexible statistical method of easy implementation  
232 used to solve class prediction problems. Moreover, the decision tree is easily  
233 interpretable because the prediction model has a tree structure with a clear decision  
234 and classification. The attribute selected to initiate the prediction of samples is defined  
235 by the root node. Sequentially, binary division occurs for a decision node with two or  
236 more branches. Finally, below the decision node is the classification and prediction of  
237 samples defined by leaves nodes (Russell and Norvig 1995; Duda et al. 2012).

238 The decision tree was built to better understand the image features and use a practical  
239 model for application in a commercial broiler slaughterhouse to classify chicken  
240 breasts into N or WB. The J48 algorithm was selected in WEKA software and used to  
241 select input fast and non-destructive parameters such as color measurements ( $L^*$ ,  $a^*$ ,  
242 and  $b^*$ ) and pH values to develop a prediction model. In addition, the model was  
243 developed by different training (70%) and testing (30%) datasets. Finally, performance  
244 was evaluated by determining the prediction model accuracy.

## 245 NIR Spectroscopy Measurements

246

247 The absorbance spectra of N and WB of chicken were obtained in the NIR range of  
248 1150–2150 nm using a portable MicroNIR 2200 spectrometer (JDSU Corporation,  
249 Santa Rosa, CA, USA) with a linear variable filter (LVF) as the dispersing element. For  
250 absorbance measurements, a collar was attached to the sensor to provide an optimal  
251 focal distance of 3 mm from the chicken breast to the spectrometer. The equipment  
252 was calibrated using a 99% diffuse reflectance standard.

253 Spectral information was acquired on the surface of N and WB of chicken skinless at  
254 25 °C, as described by De Marchi et al. (2011), at three different locations on the  
255 surface of each sample: cranial, middle, and caudal of the *pectoralis major* muscle.  
256 Before each measurement, the lens was cleaned with 70% ethanol and distilled water  
257 and dried using soft paper.

258

## 259 *Spectral Data Processing*

260

261 Spectral data of the N and WB of chicken obtained from the MicroNIR were analyzed  
262 using the Unscrambler software (Version 9.8, Camo Software AS, Oslo, Norway). The  
263 model for identifying and classifying chicken breasts was developed using principal  
264 component analysis (PCA), which corresponds to a multivariate statistical method  
265 used to reduce the dataset without the loss of useful information (Park et al. 2001). In  
266 addition, the stepwise regression method was used by selecting wavelengths as  
267 predictors to classify N or WB of chickens. Linear discriminant analyses (LDA) with full  
268 cross-validation were used to classify chicken breasts using the selected wavelengths  
269 as predictors.

270 Physicochemical Measurements

271

272 *Color Analysis and pH* - Color was measured 24 h *post-mortem* on the bone-side  
273 surface of chicken breast by a Minolta chromameter CR-400, illuminant D65 (Minolta  
274 Camera Corp., Meter Division, Ramsey, NJ, USA) and the results were reported for  
275 lightness (L\*), redness (a\*), and yellowness (b\*) according to the Commission  
276 Internationale de l'Eclairage colour system (Commission Internationale de l'Eclairage,  
277 1978). pH was measured 24 h *post-mortem* using a contact pH-meter (Testo 205,  
278 Lenzkirch, Germany).

279

280 *Chemical Composition* - Moisture, protein, ash, and lipid contents were determined on  
281 the cranial part of the *pectoralis major* muscle according to the Association of Official  
282 Analytical Chemists (1990) in triplicate. Moisture content was determined after oven  
283 drying at 105 °C for 16 h. Crude proteins were determined by the Kjeldahl method,  
284 which involved quantifying total nitrogen with a conversion factor of 6.25. Ash content  
285 was estimated by incineration at 525 °C. In addition, lipid content was determined using  
286 the Soxhlet method by petroleum ether extraction.

287

288 Technological measurements

289

290 *Water Holding Capacity (WHC)* - WHC was determined 24 h *post-mortem* according  
291 to Hamm (1961) and modified by Carvalho et al. (2017). Cubes from the cranial area  
292 of approximately 2.0 g were placed between filter paper and pressed under 10-kg  
293 acrylic plates for 5 min. WHC was determined using the equation:  $100 - [(W_i - W_f/W_i) \times 100]$ ,  
294 where  $W_i$  and  $W_f$  were the initial and final weights, respectively.

295 *Cooking Loss (CL)* - CL was determined as described by Honikel (1998) with minor  
296 modifications. After 24 h *post-mortem*, cubes from the cranial area were weighed (75  
297  $\pm$  5 g) and placed in sealed packages and then cooked until the internal temperature  
298 reached 75 °C. CL was obtained using the following equation:  $100 - [(W_i - W_f)/W_i] \times$   
299  $100]$ , where  $W_i$  and  $W_f$  were the initial and final sample weights, respectively.

300

301 *Texture* - Shear force (SF) was measured in the cranial area of the chicken breasts  
302 (raw and cooked) according to Honikel (1998) with minor modifications. Chicken breast  
303 cuts were placed in separate plastic bags and heated until the internal temperature  
304 reached 75 °C. Next, raw and cooked chicken breast were cut into 2 × 1 × 1 cm  
305 rectangular pieces. SF was obtained using the texturometer Micro Stable Systems TA-  
306 XT2i (Stable Micro Systems, Godalming, Surrey, UK) and samples were sheared  
307 perpendicularly to the fibers with a Warner Bratzler shear blade. Testing conditions  
308 were: pretest speed 10.0 mm/s, test speed 5.0 mm/s, posttest speed 10.0 mm/s, and  
309 distance 20 mm as described by Wilhelm et al. (2010).

310

311 *Statistical Analyses* - The physicochemical (moisture, ashes, proteins and lipids, color,  
312 and pH) and technological (WHC, CL, and SF) parameters of N and WB of chicken  
313 were compared by applying Student's *t*-test using Statistica 8.0 software (StatSoft,  
314 Tulsa, OK, USA).

315

## 316 **Results and Discussion**

317

318 Computer Vision System

319 To examine different training/testing compositions and thus provide a more realistic  
320 evaluation scenario, induction was performed as described. Table 2 presents a  
321 summary of the performance results obtained using the four classifiers during the  
322 experiments ordered by accuracy. As shown, SVM showed superior performance with  
323 an accuracy above of 90%. The higher F-measure values for all classification  
324 techniques indicate that the predictive task could be explained by the image features.  
325 A holdout sampling approach was used, which consisted of randomly picking 70% of  
326 the data for training and the remaining cases for testing trained classifiers.

327 Fig. 3 shows a boxplot representation of the induced models' accuracies.  
328 SVM was the only model without outliers. Both MLP and J48 presented narrow boxes,  
329 indicating stability, but also presented outliers in contrast to the previous statement.  
330 RF showed similar behavior as SVM, but with lower accuracy and the presence of  
331 outliers.

332 SVMs were first projected to deal with binary classification problems and  
333 high dimensional data, thus achieving the best results overall. However, because of  
334 the manipulation of the kernel function to explore non-linear relationships in the data,  
335 the resulting model may lack in interpretability. The generated hyperplane equation did  
336 not reveal the relationships between image features and WB myopathy.

337 ANN are very powerful and flexible tools for modeling diverse types of  
338 problems. In fact, MLPs are universal function approximators (Hornik et al. 1989) and,  
339 in our experiments achieved a performance rate very similar to that of SVM. However,  
340 in this approach, a satisfactory performance result lies in the proper choice of network  
341 architecture, which may be determined by extensive experimentation. Additionally, the  
342 resulting model does not give clear information regarding how to explain features  
343 combined to model the task.

344           The RF bagging approach combines many weak, simpler classifiers in an  
345 ensemble. The use of bootstrap sampling to compose each forest's classifier makes  
346 this technique robust against unbalanced (which was not our case) and noisy data.  
347 However, the aggregation of many models makes ensemble comprehension a difficult  
348 task. Each tree predictor uses different cases for its construction, limiting the  
349 understanding of relationships among image features and WB occurrence.

350           The choice of a proper classification algorithm depends on the application  
351 to be developed and its requirements. In this study, we compared different techniques  
352 based on diverse theoretical foundations to analyze their behavior for N and WB of  
353 chicken identification and classification.

354           All identification and classification models shared the same training and test  
355 sets during the evaluation rounds, and misclassification rates for each chicken breast  
356 were measured independently of each classifier. Fig. 4 shows the misclassification rate  
357 obtained when considering all tested classification approaches. The number of  
358 misclassifications of an instance was normalized by the cases to which the sample  
359 belonged in the evaluation sets.

360           In this sense, chicken breast 34 deserves special attention, as it belongs to  
361 the N class. As shown in Fig. 4, all classifiers presented higher misclassification rates  
362 in predicting this specific sample. In fact, in 20 of 50 repetitions, this instance was  
363 chosen in testing sets, and nearly no predictors could correctly classify this sample.  
364 Some visual aspects were observed in the corresponding picture (Fig. 5) comparing  
365 chicken breast 34 image before and after contrast enhancement.

366           High levels of striations were observed in the sample. Image texture  
367 features describe this type of characteristic as a repetition pattern, i.e., visual  
368 properties of WB myopathy. Therefore, the classifier models interpreted chicken breast

369 34 as a case of WB of chicken, justifying the high error rates obtained. It is important  
370 to consider that the source of information from a CVS is the visual appearance, which  
371 may be adversely affected by external factors, such as inappropriate illumination or  
372 sample handling. In the last case, skin regions not removed from carcasses may be  
373 interpreted as striations or repetition patterns. Image acquisition is one of the most  
374 challenging steps of a CVS and affect the system's performance.

375

## 376 Decision Tree

377

378 The physicochemical and technological parameters of N and WB of chickens were  
379 used to build an alternative tool for assessing WB myopathy in chicken breast. Using  
380 this decision tree algorithm, it is possible to observe which of the properties separate  
381 according to the N and WB of chickens. In this manner, a decision tree was constructed  
382 using information from non-destructive and fast acquisition techniques, such as pH  
383 value and color measurements ( $L^*$ ,  $a^*$ , and  $b^*$ ). For this model, the  $L^*$  (luminosity)  
384 was the attribute showing the highest gain of information, followed by pH (Fig. 6).

385 An accuracy of 88.75% was achieved for cross-validation. The  
386 implementation of the decision tree in industrial lines may enable rapid prediction of  
387 quality and optimization of product inspection. The classification of samples as N or  
388 WB of chickens would not require specialized technicians, sophisticated instruments,  
389 and the use of harmful reagents and reduces time and costs.

390

## 391 Near-Infrared Spectroscopy

392

### 393 *Spectral Characteristics of N and WB of Chickens*

394 Spectral information has been used in previous studies to predict the quality of chicken  
395 breast (Barbin et al. 2015; Wold et al. 2017). Each molecular combination results in  
396 different absorptions in the NIR electromagnetic range such as C-H, O-H, and N-H at  
397 wavelengths of 1100–1400, 1450, and 1460–1570 nm, respectively (Williams and  
398 Norris 1987; Shenk 1992; Alexandrakis et al. 2012).

399 Loadings of the third principal component (PC3) of the N and WB of  
400 chickens showed noise in the data and, therefore, only the first two principal  
401 components (PC1 and PC2) were considered for wavelength selection (Fig. 7).

402 PCA scores (Fig. 8) of the first two principal components of N and WB  
403 chicken breasts samples accounted for 97.1% of the variation among the evaluated  
404 samples. In addition, spectral data obtained from the N and WB of chicken was  
405 effective for identifying and separating the samples.

406 According to Table 3, N and WB of chickens showed significant differences  
407 in the chemical composition such as increased moisture and lipid contents and  
408 decreased total protein content. Therefore, these results agree with those of previous  
409 studies (Wold et al. 2017) and confirm that the occurrence of the WB myopathy alters  
410 the chemical attributes of chicken breast which can be distinguished in the NIR range.

411 The best separation among chicken breast was obtained using the  
412 information from the cranial area rather than the middle and caudal regions of the  
413 sample. The spectral information in the NIR range provided satisfactory separation  
414 between samples from two classes, in part because of differences in quality  
415 parameters between these classes. This observation agrees with previous findings  
416 reporting that the cranial area of the muscle is more severely affected by WB myopathy  
417 (Sihvo et al. 2014; Sihvo et al. 2017).

418           Successful results were obtained from NIR spectroscopy aiming to identify  
419 chicken breast affected by WB myopathy, and, therefore is a fast and useful tool that  
420 can be applied in chicken slaughtering lines. Using the stepwise regression method,  
421 compared to PCA, some essential wavelengths were selected for classifying N or WB  
422 of chickens. Among the MicroNIR 2200 electromagnetic range (1150–2150 nm), 6  
423 wavelengths were identified, corresponding to 1281.05, 1378.85, 1452.2, 1639.65,  
424 1835.25, and 1941.2 nm.

425           Classification of N and WB of chickens showed 97.5% accuracy, and only  
426 two chicken breasts samples were improperly classified (from a total of 80 chicken  
427 breasts). In contrast, cross-validation showed a lower accuracy of 96.3% and three  
428 chicken breasts were misclassified. However, among these samples, two were also  
429 improperly classified by the other methods investigated in this study. Thus, these  
430 samples can be considered as analytical outliers. Therefore, both ratings were  
431 considered satisfactory for classifying the samples into N or WB of chickens. More  
432 importantly, better results were obtained compared to the CVS approach.

433

#### 434 Physicochemical and Technological Parameters of N and WB of Chickens

435

436 The chemical composition of N and WB of chickens showed significant differences  
437 between classes (Table 3). WB of chicken showed a moisture content that was 2.21%  
438 higher than that of N chicken breast. The same results were observed by Soglia et al.  
439 (2016), who reported the chemical composition of N, WB, WS, and WB/WS  
440 (simultaneous occurrence of abnormalities on the same broiler breast). The higher  
441 moisture observed in WB of chickens indicates possible edemas associated with  
442 inflammatory conditions (Mazzoni et al. 2015; Sihvo et al. 2014).

443 WB of chicken also showed a 106.67% higher lipid content than N chicken  
444 breast. Previous studies showed histopathological changes as degeneration of muscle  
445 fibers and increased intramuscular lipids due to accumulation of adipocytes at the  
446 perimysium, which may explain the increased lipid content on the affected *pectoralis*  
447 *major* muscle (Mazzoni et al. 2015; Mudalal et al. 2015; Soglia et al. 2016; Trocino et  
448 al. 2015; Velleman and Clark 2015).

449 Proteins content is an important characteristic of meat and influences meat  
450 nutritional properties, appearance, and texture (Xiong 2004; Mudalal et al. 2014). WB  
451 of chicken showed 14.41% lower protein content than N chicken breast, similar results  
452 were observed by Mudalal et al. (2014) and Soglia et al. (2016). The significant  
453 reduction in protein content was associated with a reduced fiber number and muscle  
454 tissue degeneration, particularly myofibrillar and sarcoplasmic proteins (Mudalal et al.  
455 2014; Sihvo et al. 2014). Sihvo et al. (2014), suggested that WB and WS can occur on  
456 the same chicken breast, and Kuttappan et al. (2013) categorized WS abnormalities  
457 as normal, moderate, or severe depending on the degree of WS. It was previously  
458 reported that as the severity of the condition increased, protein content was  
459 dramatically reduced (Mazzoni et al. 2015).

460 The ash content of WB of chicken was 13.04% lower than in N chicken  
461 breast. Similar results were reported by Mazzoni et al. (2015), with the reduction in  
462 mineral content attributed to the occurrence of muscular dystrophy when membrane  
463 damage occurred, with consequent loss of cellular liquids.

464 WB of chicken showed higher ultimate pH *post-mortem* compared with N  
465 chicken breast (Table 4), similar results were obtained by Mudalal et al. (2014) and  
466 Trocino et al. (2015). This result demonstrated that the muscle degeneration process  
467 decreases the glycolytic potential, reducing lactic acid content and modifying

468 acidification during *post-mortem* of *pectoralis major* muscle affected by WB myopathy  
469 (Berri et al. 2001; Mudalal et al. 2014; Sihvo et al. 2014). For the color of meat,  
470 *pectoralis major* muscle affected by WB myopathy showed significantly higher values  
471 for L\*, a\*, and b\*. Therefore, the appearance of WB of chicken was altered, with more  
472 pale areas and yellow color, as previously reported by Mudalal et al. (2015), Sihvo et  
473 al. (2014) and Trocino et al. (2015).

474           During the cooking process, structural changes in actin and myosin occur  
475 because of myofibrillar proteins denaturation, reducing the amount of water in the  
476 muscle tissue of meat (Bertola et al. 1994). The decreased water content is highly  
477 correlated with the reduction of myofibrillar protein content. Therefore, the higher value  
478 for cooking loss observed in WB of chicken can be explained by the occurrence of  
479 degeneration and consequent reduction in protein content, particularly myofibrillar  
480 protein (Mudalal et al. 2014; Sihvo et al. 2014). In addition, the WHC of WB of chicken  
481 was 106.06% lower than in N chicken breast. Previous studies reported that lower  
482 WHC in WB of chicken can be associated with a higher ultimate pH *post-mortem*  
483 exhibited in the affected *pectoralis major* muscle (Mudalal et al. 2015) and reduced  
484 protein content, particularly myofibrillar protein (Petracchi et al. 2013).

485           As a result of muscle atrophy associated with variable amounts of interstitial  
486 connective tissue accumulation or fibrosis, raw WB of chicken showed 49.51% greater  
487 hardness (shear force) than N chicken breast, in agreement with the results of Sihvo  
488 et al. (2014) and Trocino et al. (2015), who found that the *pectoralis major* muscle  
489 affected by WB myopathy showed greater hardness consistency. In contrast, after  
490 cooking, WB of chicken was 31.79% softer (Table 3). Histological evaluation reported  
491 by Sihvo et al. (2014), Trocino et al. (2015), and Velleman and Clark (2015), revealed  
492 structural changes in WB of chicken, such muscle degeneration of muscle fiber

493 associated with fat intramuscular accumulation or lipidosis. This could be explained as  
494 the fat content directly influences the softness of meat.

495

496 Application of CVS Approaches, NIR Spectroscopy, and Physicochemical and  
497 Technological Parameters to Identify and Classify WB of Chicken

498

499 CVS approaches, NIR spectroscopy, and physicochemical and technological  
500 measurements were performed in order to propose a rapid and non-destructive  
501 technique for identifying and classifying N and WB of chicken. In relation to CVS  
502 results, superior performance was achieved using the SVM algorithm with an accuracy  
503 of 91.83%. NIR spectroscopy showed higher performance, with an accuracy of  
504 97.50%. Therefore, successful accuracy was obtained for both nondestructive and fast  
505 techniques and proved to be a potential method to be implemented in chicken  
506 slaughter lines to predict the quality, identify and classify as N or WB of chickens.

507         The application of NIR spectroscopy in the food industry has some  
508 advantages, although there are limitations to its use such as lower sensitivity for  
509 identifying the smaller constituents of food. It is recommended that for each food group,  
510 a method of application of NIR spectroscopy should be developed, as each type of  
511 food is composed of a complex food matrix. In addition, calibration procedures require  
512 more time, and the choice of spectral data processing is complex (Iwamoto and  
513 Kawano 1992). In contrast, CVS results are influenced by the quality of images and  
514 standardization of ambient lighting. Otherwise, they may generate inadequate results  
515 and be interpreted with errors (Shearer and Holmes 1990). Thus, both NIR  
516 spectroscopy as CVS have advantages and disadvantages, and their implementation  
517 is strictly related to the specialist knowledge and solution set up.

## 518 **Conclusions**

519

520 The occurrence of WB myopathy in broilers caused visual, technological, and  
521 physicochemical changes in chicken breasts. Among them, chicken breasts affected  
522 by WB myopathy showed significant color changes with increased L\*, a\*, b\*, and pH  
523 values. Texture analyses revealed that raw WB of chicken presented consistent  
524 hardness values, but after cooking was softer than N chicken breast. In addition, WB  
525 of chicken showed increased moisture and lipid contents, reduced mineral and protein  
526 contents, and inferior technological quality with reduced water holding capacity. To  
527 identify this myopathy, we applied two different rapid, nondestructive, and accurate  
528 methods. NIR spectroscopy and CVS approaches showed high accuracy in identifying  
529 and classify of WB myopathy, and both systems can be successfully implemented in  
530 chicken slaughtering lines to classify chicken breast based on this specific condition.

531 **Acknowledgements** The authors thank the Conselho Nacional de Desenvolvimento  
532 Científico e Tecnológico (CNPq) / Brazil for granting Master's Scholarships for  
533 Geronimo, B.C. and Mastelini, S. M., Post Doctoral Fellowship to Carvalho, R. H. and  
534 Research Fellow to Ida, E.I.

535

## 536 **References**

537

538 Alexandrakis, D., Downey, G., & Scannell, A. G. (2012). Rapid non-destructive  
539 detection of spoilage of intact chicken breast muscle using near-infrared and  
540 Fourier transform mid-infrared spectroscopy and multivariate statistics. *Food and*  
541 *Bioprocess Technology*, 5 (1), 338–347.

- 542 AOAC (1990). Official methods of analysis of AOAC international (15<sup>th</sup> ed.), AOAC  
543 International, Washington, DC, USA.
- 544 Balaji, G., Subashini, T., & Chidambaram, N. (2015). Automatic classification of cardiac  
545 views in echocardiogram using histogram and statistical features. *Procedia  
546 Computer Science*, 46 (0), 1569–1576.
- 547 Barbin, D. F., ElMasry, G., Sun, D.-W., & Allen, P. (2013). Non-destructive  
548 determination of chemical composition in intact and minced pork using near-  
549 infrared hyperspectral imaging. *Food chemistry*, 138 (2), 1162–1171.
- 550 Barbin, D. F., Kaminishikawahara, C. M., Soares, A. L., Mizubuti, I. Y., Grespan, M.,  
551 Shimokomaki, M., & Hirooka, E. Y. (2015). Prediction of chicken quality attributes  
552 by near infrared spectroscopy. *Food chemistry*, 168, 554–560.
- 553 Barbin, D. F., Mastelini, S. M., Barbon, S., Campos, G. F., Barbon, A. P. A., &  
554 Shimokomaki, M. (2016). Digital image analyses as an alternative tool for chicken  
555 quality assessment. *Biosystems Engineering*, 144, 85–93.
- 556 Berri, C., Wacrenier, N., Millet, N., & Le Bihan-Duval, E. (2001). Effect of selection for  
557 improved body composition on muscle and meat characteristics of broilers from  
558 experimental and commercial lines. *Poultry Science*, 80 (7), 833–838.
- 559 Bertola, N., Bevilacqua, A., & Zaritzky, N. (1994). Heat treatment effect on texture  
560 changes and thermal denaturation of proteins in beef muscle. *Journal of Food  
561 Processing and Preservation*, 18 (1), 31–46.
- 562 Breiman, L. (2001). *Random forests*. *Machine learning*, 45 (1), 5–32.

- 563 Campos, G. F., Barbon, S., & Mantovani, R. G. (2016). A meta-learning approach for  
564 recommendation of image segmentation algorithms. In: *Graphics, Patterns and*  
565 *Images, 29th SIBGRAPI Conference on*. IEEE, 370–377
- 566 Campos, G. F. C., Igawa, R. A., Seixas, J. L., Almeida, A. M. G., Guido, R. C., &  
567 Barbon, S. (2016a). Supervised approach for indication of contrast enhancement  
568 in application of image segmentation. In: *MMEDIA 2016, The Eighth International*  
569 *Conferences on Advances in Multimedia*. 12–18.
- 570 Carvalho, R. H., Ida, E. I., Madruga, M. S., Martínez, S. L., Shimokomaki, M., &  
571 Estévez, M. (2017). Underlying connections between the redox system  
572 imbalance, protein oxidation and impaired quality traits in pale, soft and exudative  
573 (pse) poultry meat. *Food chemistry*, 215, 129–137.
- 574 Commission Internationale de l'Eclairage, C. I. (1978). *Recommendations on uniform*  
575 *color spaces-color difference equations, psychometric color terms*. Paris: CIE.
- 576 De Marchi, M., Penasa, M., Battagin, M., Zanetti, E., Pulici, C., & Cassandro, M.  
577 (2011). Feasibility of the direct application of near-infrared reflectance  
578 spectroscopy on intact chicken breasts to predict meat color and physical traits.  
579 *Poultry science*, 90 (7), 1594–1599.
- 580 Deka, P. C., & Raghavendra, S. (2014). Support vector machine applications in the  
581 field of hydrology: a review. *Applied soft computing*, 19, 372–386.
- 582 Duda, R. O., Hart, P. E., & Stork, D. G. (2012). *Pattern classification*. John Wiley &  
583 Sons.
- 584 Fletcher, D. (2004). Further processing of poultry. In: *Poultry meat processing and*  
585 *quality* (pp. 108-134). Boca Raton, Florida: CRC Press.

- 586 Galasso, H. L., Callier, M. D., Bastianelli, D., Blancheton, J.-P., & Aliaume, C. (2017).  
587 The potential of near infrared spectroscopy (nirs) to measure the chemical  
588 composition of aquaculture solid waste. *Aquaculture*, 476, 134–140.
- 589 Gonzalez, R. C., & Woods, R. C. (2010). *Processamento Digital De Imagens*. São  
590 Paulo: Pearson Prentice Hall.
- 591 Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., & Witten, I. H. (2009).  
592 The weka data mining software: An update. *ACM SIGKDD explorations*  
593 *newsletter*, 11 (1), 10–18.
- 594 Hamm, R. (1961). Biochemistry of meat hydration. *Advances in food research*, 10,  
595 355–463.
- 596 Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural features for image  
597 classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 6, 610–  
598 621.
- 599 Honikel, K. O. (1998). Reference methods for the assessment of physical  
600 characteristics of meat. *Meat science*, 49 (4), 447–457.
- 601 Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are  
602 universal approximators. *Neural networks*, 2 (5), 359–366.
- 603 Ignat, T., Lurie, S., Nyasordzi, J., Ostrovsky, V., Egozi, H., Hoffman, A., & Schmilovitch,  
604 Z. E. (2014). Forecast of apple internal quality indices at harvest and during  
605 storage by VIS-NIR spectroscopy. *Food and bioprocess technology*, 7(10), 2951-  
606 2961.

- 607 Iwamoto, M., Kawano, S. (1992). Advantages and disadvantages of nir applications for  
608 the food industry. *Making light work: Advances in near infrared spectroscopy*,  
609 367–375.
- 610 Kuttappan, V., Brewer, V., Apple, J., Waldroup, P., & Owens, C. (2012). Influence of  
611 growth rate on the occurrence of white striping in broiler breast fillets. *Poultry*  
612 *Science*, 91 (10), 2677–2685.
- 613 Kuttappan, V., Huff, G., Huff, W., Hargis, B., Apple, J., Coon, C., & Owens, C. (2013).  
614 Comparison of hematologic and serologic profiles of broiler birds with normal and  
615 severe degrees of white striping in breast fillets. *Poultry Science*, 92 (2), 339–  
616 345.
- 617 Li, D., Li, N., Wang, J., & Zhu, T. (2015). Pornographic images recognition based on  
618 spatial pyramid partition and multi-instance ensemble learning. *Knowledge-*  
619 *Based Systems*, 84, 214 – 223.
- 620 Livingstone, D. J. (2008). *Artificial Neural Networks: Methods and Applications*  
621 *(Methods in Molecular Biology)*, Humana Press.
- 622 Mazzoni, M., Petracci, M., Meluzzi, A., Cavani, C., Clavenzani, P., & Sirri, F. (2015).  
623 Relationship between *pectoralis major* muscle histology and quality traits of  
624 chicken meat. *Poultry Science*, 94 (1), 123–130.
- 625 Mudalal, S., Babini, E., Cavani, C., & Petracci, M. (2014). Quantity and functionality of  
626 protein fractions in chicken breast fillets affected by white striping. *Poultry*  
627 *Science*, 93 (8), 2108–2116.

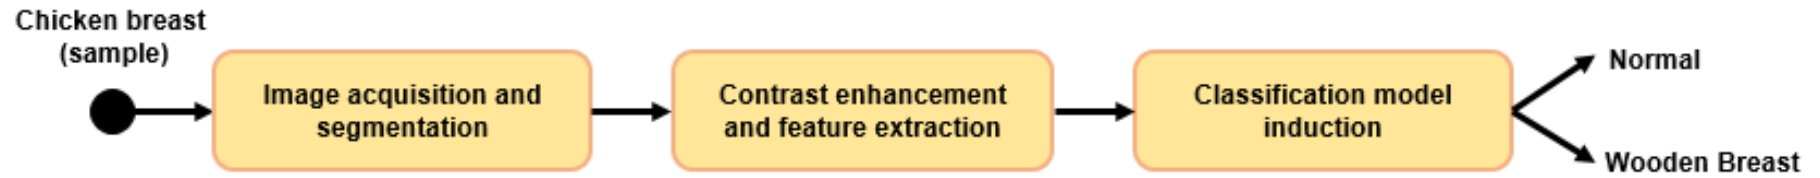
- 628 Mudalal, S., Lorenzi, M., Soglia, F., Cavani, C., & Petracci, M. (2015). Implications of  
629 white striping and wooden breast abnormalities on quality traits of raw and  
630 marinated chicken meat. *Animal*, 9 (04), 728– 734.
- 631 Mutryn, M. F., Brannick, E. M., Fu, W., Lee, W. R., & Abasht, B. (2015).  
632 Characterization of a novel chicken muscle disorder through differential gene  
633 expression and pathway analysis using rna-sequencing. *BMC genomics*, 16 (1),  
634 399.
- 635 Nixon, M. S., & Aguado, A. S. (2012). *Feature extraction & image processing for*  
636 *computer vision*. Academic Press. London: Elsevier.
- 637 Ojala, T., Pietikainen, M., & Maenpaa, T. (2002). Multiresolution gray-scale and  
638 rotation invariant texture classification with local binary patterns. *IEEE*  
639 *Transactions on Pattern Analysis and Machine Intelligence*, 24 (7), 971–987.
- 640 Papadopoulou, O. S., Panagou, E. Z., Mohareb, F. R., & Nychas, G. J. E. (2013).  
641 Sensory and microbiological quality assessment of beef fillets using a portable  
642 electronic nose in tandem with support vector machine analysis. *Food Research*  
643 *International*, 50 (1), 241 – 249.
- 644 Park, B., Chen, Y.-R., Hruschka, W. R., Shackelford, S. D., & Koohmaraie, M. (2001).  
645 Principal component regression of near-infrared reflectance spectra for beef  
646 tenderness prediction. *Transactions of the ASAE*, 44 (3), 609.
- 647 Petracci, M., Bianchi, M., Mudalal, S., & Cavani, C. (2013). Functional ingredients for  
648 poultry meat products. *Trends in food science & technology*, 33 (1), 27–39.
- 649 Petracci, M., Mudalal, S., Soglia, F., & Cavani, C. (2015). Meat quality in fast-growing  
650 broiler chickens. *World's Poultry Science Journal*, 71 (2), 363–374.

- 651 Porep, J. U., Kammerer, D. R., & Carle, R. (2015). On-line application of near infrared  
652 (nir) spectroscopy in food production. *Trends in Food Science & Technology*, 46  
653 (2), 211–230.
- 654 Prevolnik, M., Škrlep, M., Janeš, L., Velikonja-Bolta, Š., Škorjanc, D., & Čandek-  
655 Potokar, M. (2011). Accuracy of near infrared spectroscopy for prediction of  
656 chemical composition, salt content and free amino acids in dry-cured ham. *Meat  
657 science*, 88(2), 299-304.
- 658 Quinlan, R. (1993). *C4.5: Programs for Machine Learning*. San Mateo, CA: Morgan  
659 Kaufmann Publishers.
- 660 Russell, S., & Norvig, P. (1995). A modern approach. *Artificial Intelligence*. Prentice-  
661 Hall, Englewood Cliffs, 25, 27.
- 662 Shearer, S. A., & Holmes, R. (1990). Plant identification using color co-occurrence  
663 matrices. *Transactions of the ASAE*, 33 (6), 1237–1244.
- 664 Shenk, J. (1992). Application of nir spectroscopy to agricultural products. *Handbook of  
665 near-infrared analysis*, 383–431.
- 666 Sihvo, H.-K., Immonen, K., & Puolanne, E. (2014). Myodegeneration with fibrosis and  
667 regeneration in the *pectoralis major* muscle of broilers. *Veterinary Pathology*, 51  
668 (3), 619–623.
- 669 Sihvo, H.-K., Lindén, J., Airas, N., Immonen, K., Valaja, J., & Puolanne, E. (2017).  
670 Wooden breast myodegeneration of *pectoralis major* muscle over the growth  
671 period in broilers. *Veterinary Pathology*, 54 (1), 119–128.

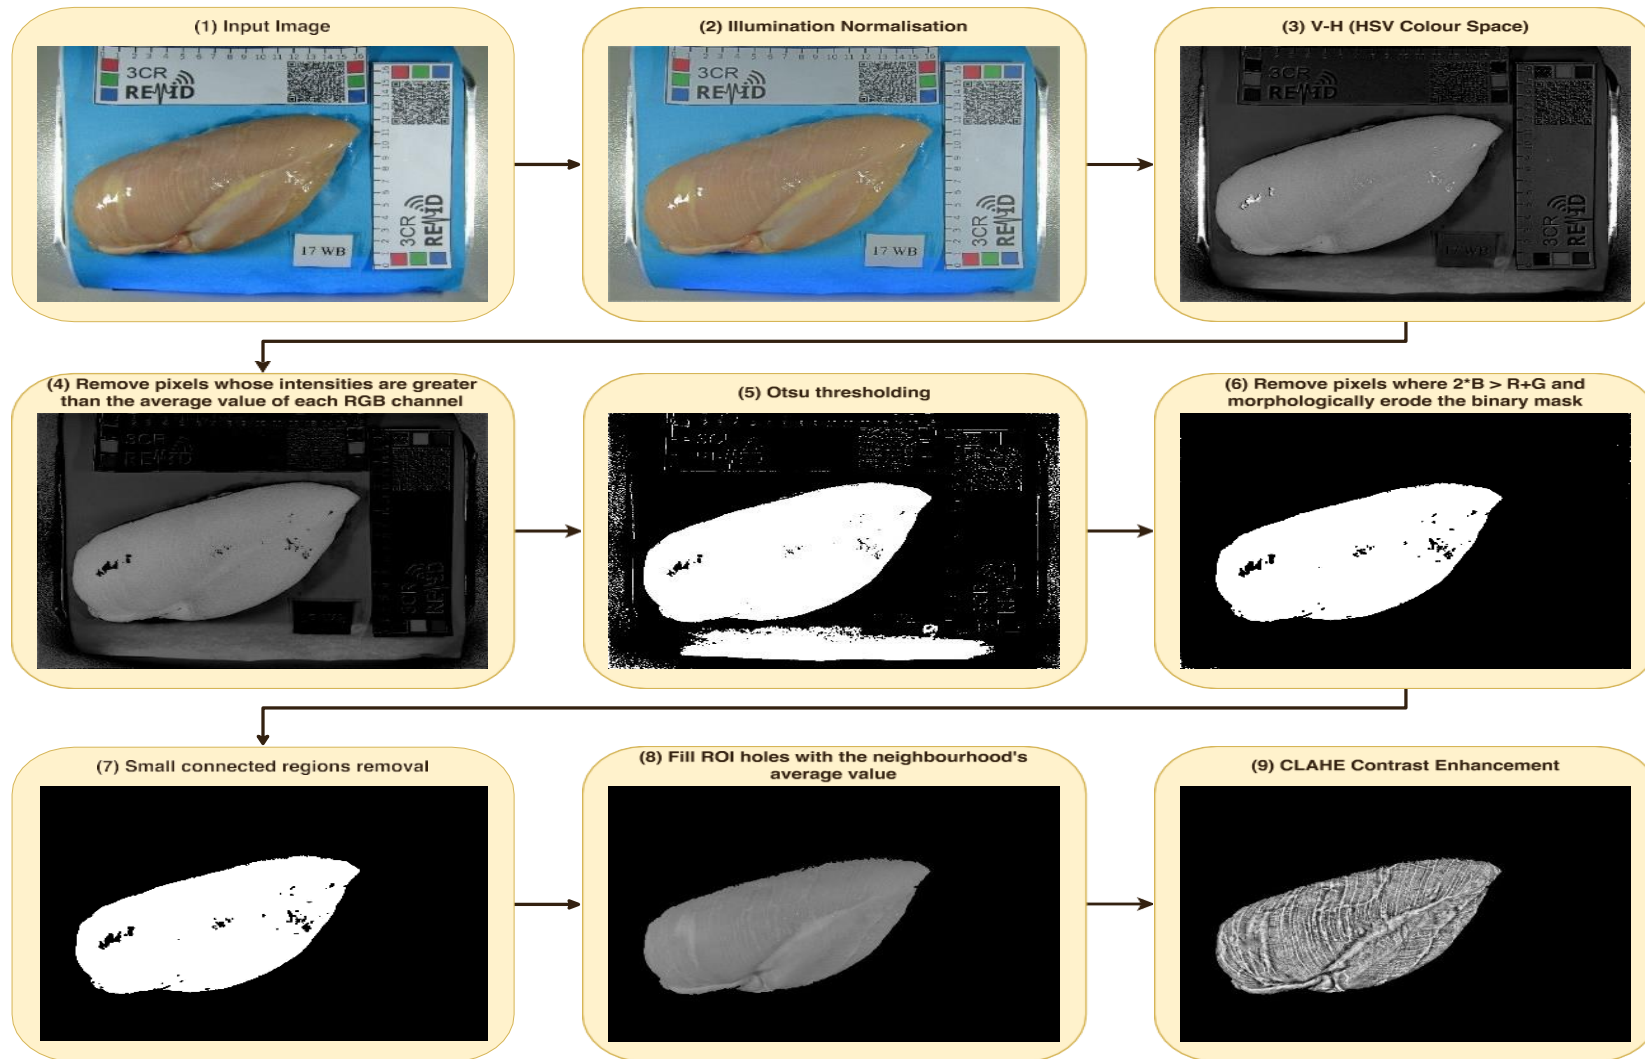
- 672 Soglia, F., Laghi, L., Canonico, L., Cavani, C., & Petracci, M. (2016). Functional  
673 property issues in broiler breast meat related to emerging muscle abnormalities.  
674 *Food Research International*, 89, 1071–1076.
- 675 Sun, D. W. (Ed.). (2016). *Computer vision technology for food quality evaluation*.  
676 Academic Press. London: Elsevier.
- 677 Trocino, A., Piccirillo, A., Birolo, M., Radaelli, G., Bertotto, D., Filiou, E., Petracci, & M.,  
678 Xiccato, G. (2015). Effect of genotype, gender and feed restriction on growth,  
679 meat quality and the occurrence of white striping and wooden breast in broiler  
680 chickens. *Poultry science*, 94 (12), 2996–3004.
- 681 Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*. New York: Springer.
- 682 Velleman, S. G., & Clark, D. L. (2015). Histopathologic and myogenic gene expression  
683 changes associated with wooden breast in broiler breast muscles. *Avian*  
684 *diseases*, 59 (3), 410–418.
- 685 Wilhelm, A. E., Maganhini, M. B., Hernández-Blazquez, F. J., Ida, E. I., &  
686 Shimokomaki, M. (2010). Protease activity and the ultrastructure of broiler  
687 chicken pse (pale, soft, exudative) meat. *Food Chemistry*, 119 (3), 1201–1204.
- 688 Williams, P., & Norris, K. (1987). *Near-infrared technology in the agricultural and food*  
689 *industries*. American Association of Cereal Chemists, Inc.
- 690 Wold, J. P., Veiseth-Kent, E., Høst, V., & Løvland, A. (2017). Rapid on-line detection  
691 and grading of wooden breast myopathy in chicken fillets by near-infrared  
692 spectroscopy. *PloS one*, 12 (3), e0173384.
- 693 Xiong, Y. (2004). *Muscle proteins*. Cambridge, UK: Woodhead Publishing.


- 694 Ye, M., Yue, T., Yuan, Y., & Li, Z. (2014). Application of FT-NIR spectroscopy to apple  
695 wine for rapid simultaneous determination of soluble solids content, pH, total  
696 acidity, and total ester content. *Food and bioprocess technology*, 7(10), 3055-  
697 3062.
- 698 Zuiderveld, K., (1994). Contrast limited adaptive histogram equalization. In: *Graphics*  
699 *gems IV* (Ed), (pp. 474-123). San Diego, CA: Academic Press Professional.

**Figure 1** Overview of the proposed Computer Vision System.



**Figure 2** Performed image processing steps in the CVS evaluation



**Figure 3** Overall algorithms' performance


SVM Support Vector Machines  
MLP Multilayer Perceptron  
RF Random Forest



**Figure 5** Chicken breast 34, belonging to the Normal class and misclassified in almost all cases, by all classification techniques tested.

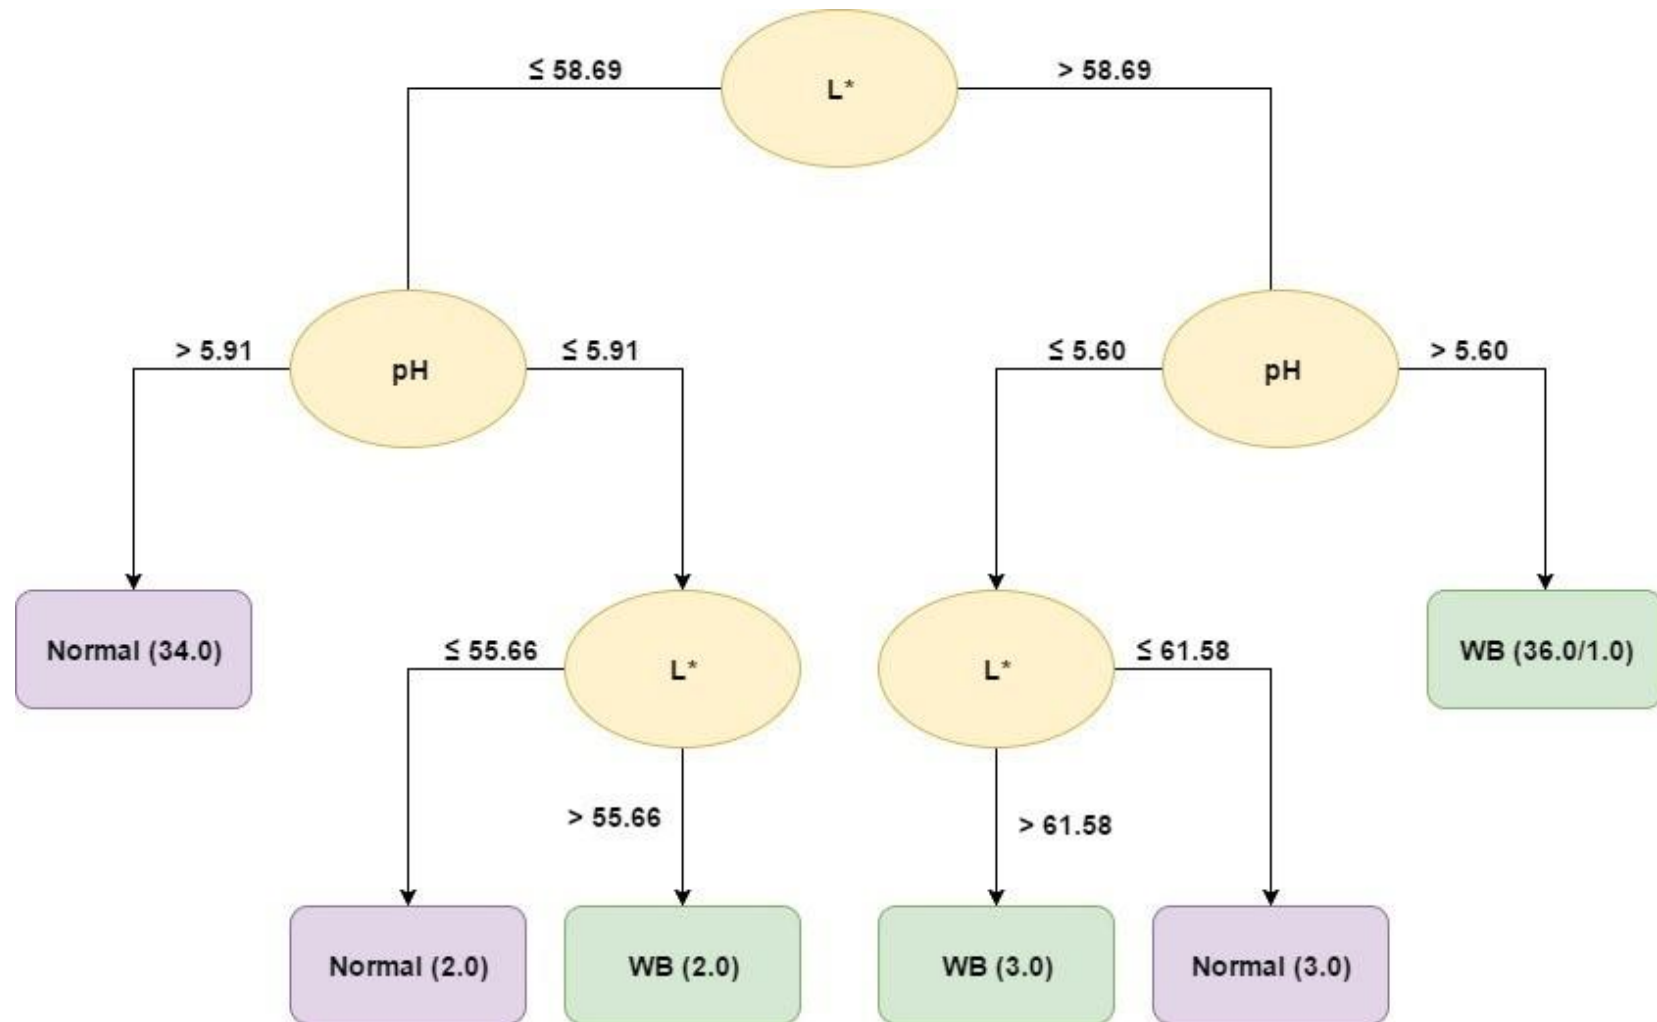


(a) Original Image


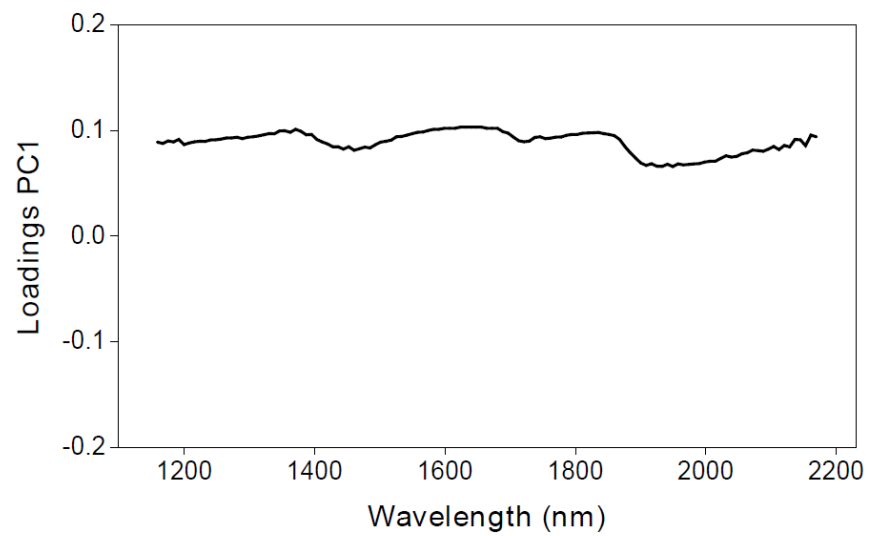


(b) Resulting image after image processing steps


**Figure 6** Decision tree from non-destructive and fast techniques of chicken breast meat quality



**Figure 7** Loadings plot of the first two principal components for spectral data of WB and N chicken breast



**Figure 8** Score plot of the first two principal components for spectral data of WB and N chicken breast



**Table 1** List of all image features used in the proposed approach for Wooden Breast assessment

<b>No.</b>	<b>Type</b>	<b>Name</b>	<b>Description</b>
1	Intensity	MeanInten	Mean value of intensity image
2	Intensity	StdInten	Standard deviation of intensity image
3	Intensity	EntropyInten	Entropy of intensity image
4	Intensity	StdHistInten	Standard deviation of intensity image histogram
5	Intensity	KurtHistInten	Kurtosis of intensity image histogram
6	Intensity	ShewHistInten	Skewness of intensity image histogram
7 - 16	Texture	LBP	Vector of Local Binary Patterns (LBP) rationally invariant features

**Table 2** Performance metrics of algorithm

Algorithm	Accuracy		F-Measure	
	Mean	Std	mean	Std
SVM (%)	91.83	5.39	91.80	5.42
MLP (%)	90.67	4.34	90.60	4.42
RF (%)	87.83	4.82	87.75	4.89
J48 (%)	85.25	5.72	85.04	5.98

Std standard deviation

SVM Support Vector Machines

MLP Multilayer Perceptron

RF Random Forest

**Table 3** Chemical composition of normal (N) and wooden breast (WB) of chicken

Parameters	N		WB	
	mean	Std	Mean	Std
Moisture (%)	74.98 <sup>b</sup>	0.59	76.64 <sup>a</sup>	1.21
Lipids (%)	1.20 <sup>b</sup>	0.40	2.48 <sup>a</sup>	0.64
Protein (%)	24.70 <sup>a</sup>	1.59	21.14 <sup>b</sup>	1.80
Ash (%)	1.15 <sup>a</sup>	0.09	1.00 <sup>b</sup>	0.14

Std standard deviation

<sup>a,b</sup> Different letters on the same line were statistically different according to Student's t- test ( $p < 0.01$ ).

**Table 4** Effect of normal (N) and wooden breast (WB) myopathy on physical and technological parameters

Parameters	N		WB	
	Mean	Std	mean	Std
pH	5.74 <sup>b</sup>	0.11	5.85 <sup>a</sup>	0.16
L*	56.12 <sup>b</sup>	2.41	61.71 <sup>a</sup>	2.13
a*	1.62 <sup>b</sup>	0.74	2.66 <sup>a</sup>	0.85
b*	5.97 <sup>b</sup>	1.83	7.36 <sup>a</sup>	2.01
CL (%)	16.48 <sup>b</sup>	2.81	33.96 <sup>a</sup>	4.77
WHC (%)	65.99 <sup>a</sup>	3.62	62.44 <sup>b</sup>	3.93
SF of raw chicken breast (Newton)	12.24 <sup>b</sup>	1.70	18.30 <sup>a</sup>	6.52
SF of cooked chicken breast	37.52 <sup>a</sup>	12.17	25.59 <sup>b</sup>	5.93

CL cooking loss, WHC water holding capacity, SF shear force

Std standard deviation

<sup>a,b</sup> Different letters on the same line were statistically different according to Student's t- test ( $p < 0.01$ ).

## 6 CONCLUSÕES

- A miopatia WB provocou alterações na aparência e nos parâmetros físico-químicos e tecnológicos dos peitos de frangos. Os peitos de frangos com WB apresentaram alterações nos parâmetros físicos como aumento de pH, textura com maior rigidez no cru e maciez no cozido e alterações na cor com visualização de áreas pálidas e amareladas. Além disto, apresentaram alterações nos parâmetros químicos como aumento no teor de umidade e lipídios, e redução do teor de cinzas e proteínas. Em relação aos parâmetros tecnológicos, os peitos de frangos WB apresentaram menor capacidade de retenção de água e maior perda de água por cozimento.
- O algoritmo Máquina de Vetores de Suporte (SVM) apresentou melhor desempenho para identificação e classificação dos peitos de frango WB com 91,83% de acurácia, seguido pelo Perceptron Multicamadas (MLP), Floresta Aleatória (RF) e Árvore de Decisão (algoritmo J48) com acurácias de 90,67%, 87,83% e 85,25%, respectivamente.
- A árvore de decisão utilizando as análises não destrutivas e de rápida mensuração como medidas de cor ( $L^*$ ,  $a^*$  e  $b^*$ ) e pH permitiu solucionar e prever as classes de peitos de frango N e WB com 88,75% de acurácia
- Os dados espectrais para identificar e classificar os peitos de frangos N e WB apresentaram 97,5% de acurácia.
- As medidas de NIR e CVS como medidas rápidas e não destrutivas para identificar e classificar os peitos de frangos N e WB apresentaram acurácia satisfatória e podem ser implementadas sob condições específicas nas linhas de abatedouros comerciais.