UNIVERSIDADE DE SÃO PAULO
FACULDADE DE ZOOTECNIA E ENGENHARIA DE ALIMENTOS

KENI EDUARDO ZANONI NUBIATO

**Sistema de imagem hiperespectral para
classificação de características qualitativas da
carne de bovinos Nelore**

Pirassununga

2016

KENI EDUARDO ZANONI NUBIATO

**Sistema de imagem hiperespectral para
classificação de características qualitativas da
carne de bovinos Nelore**

Versão corrigida

Tese de doutorado apresentada à Faculdade de Zootecnia e Engenharia de Alimentos da Universidade de São Paulo, como parte dos requisitos para a obtenção do Título de Doutor em Zootecnia.

Área de Concentração: Qualidade e Produtividade Animal

Orientador: Prof. Dr. Saulo da Luz e Silva

Pirassununga

2016

Ficha catalográfica

Ficha catalográfica elaborada pelo
Serviço de Biblioteca e Informação, FZEA/USP,
com os dados fornecidos pelo(a) autor(a)

N962s Nubiato, Keni Eduardo Zanoni
 Sistema de imagem hiperespectral para
 classificação de características qualitativas da
 carne de bovinos Nelore / Keni Eduardo Zanoni
 Nubiato ; orientador Saulo da Luz e Silva. --
 Pirassununga, 2016.
 102 f.

 Tese (Doutorado - Programa de Pós-Graduação em
 Zootecnia) -- Faculdade de Zootecnia e Engenharia
 de Alimentos, Universidade de São Paulo.

 1. Análise multivariada. 2. Qualidade de carne.
 3. Maciez. 4. Maturação. 5. pH. I. da Luz e Silva,
 Saulo, orient. II. Título.

Biografia

KENI EDUARDO ZANONI NUBIATO, filho de Waldir Nubiato e Margareth Zanoni, nasceu na cidade de Araçatuba-SP, em 27 de outubro de 1985.

Ingressou na Universidade Estadual Paulista “Júlio de Mesquita Filho”- UNESP, Faculdade de Ciências Agrárias e Tecnológicas (FCAT) em 2006 e obteve o grau de Bacharel em Zootecnia em 2010.

Em fevereiro de 2011 iniciou o Curso de Pós-Graduação em Zootecnia - Área de Concentração em Produção Animal, na Faculdade de Ciências Agrárias da Universidade Federal da Grande Dourados, realizando seus estudos na área de Qualidade da carne e obteve o grau de Mestre em Zootecnia em janeiro de 2013 com a defesa da dissertação “Qualidade da carne de cordeiros alimentados com dietas contendo grão de soja *in natura* ou desativado”.

Em fevereiro de 2013 iniciou o Curso de Pós-Graduação em Zootecnia - Área de Concentração em Qualidade e Produtividade Animal, na Faculdade de Zootecnia e Engenharia de Alimentos da Universidade de São Paulo.

Hoje, realiza a defesa de sua tese “Sistema de imagem hiperespectral para classificação de características qualitativas da carne de bovinos Nelore”, para a obtenção do grau de Doutor em Zootecnia.

Dedicatória

A Deus por me acalmar em momentos difíceis e me dar forças para conseguir trilhar os caminhos que escolhi;

A minha família, que mesmo longe em algumas vezes, sempre se fez presente nos momentos mais importantes;

A minha avó, Aparecida Zanoni, que nos deixou muito cedo, mas mesmo ausente em pessoa, me deu forças e motivação para concluir mais esta etapa de minha vida.

Agradecimentos

A Deus por toda a força e fé que precisei durante este árduo caminho;

A minha família pelo apoio e compreensão devido ao grande tempo que me ausentei;

A minha namorada, Camila Nardi, por estar presente em todos os momentos, bons ou ruins, me proporcionando sustentação emocional; pela contribuição intelectual, que auxiliou na conclusão desta tese; e pela enorme paciência e carinho que nos fizeram permanecer juntos;

À Universidade de São Paulo, pela disponibilização de área e recursos para realização do projeto;

Aos Professores que fizeram parte desta nova etapa, pela confiança, amizade, paciência, incentivo e pelo compartilhamento de seus conhecimentos;

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de estudos concedida;

Ao Conselho Nacional de Pesquisa – CNPq, pela concessão de bolsa de doutorado sanduíche no exterior;

A University of Nebraska – Lincoln por me receber durante meu doutorado sanduíche proporcionando novas experiências e novos conhecimentos;

Aos doutores Chris R. Calkins, Govindarajan Konda Naganathan, Jeyamkondan Subbiah pelo apoio e contribuição direta durante a realização do projeto de doutorado;

Aos acadêmicos do Programa de Pós-Graduação em Zootecnia pelos bons momentos que me proporcionaram em mais esta etapa de minha vida;

Aos amigos e companheiros que pude fazer durante esses 3 anos e que me acompanharam durante esta jornada;

Aos funcionários da Universidade de São Paulo por toda a dedicação e empenho, para que o projeto fosse executado da melhor maneira possível.

A todos, os meus mais sinceros agradecimentos.

Epígrafe

“Por vezes sentimos que aquilo que fazemos não é senão uma gota de água
no mar. Mas o mar seria menor se lhe faltasse uma gota”.

(Madre Teresa de Calcutá)

Resumo

NUBIATO, K.E.Z. **Sistema de imagem hiperespectral para classificação de características qualitativas da carne de bovinos Nelore**. 2016. 102f. Tese (Doutorado) – Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga, 2016.

A classificação da carne bovina quanto as suas características qualitativas tem extrema importância para indústria frigorífica, para que haja a padronização do produto final e que este possa ser destinado à nichos de mercados específicos. Sendo assim, o emprego de técnicas que possam identificar essas características e classificá-las de forma rápida, precisa e sem destruição do produto, torna-se imprescindível. Este estudo foi desenvolvido com o objetivo de avaliar a acurácia na classificação da maciez da carne maturada por 7, 14, 21 dias ou não maturadas, além da classificação do pH e do tempo de maturação utilizando um sistema de imagem hiperespectral de bancada. O sistema de imagem hiperespectral ($\lambda = 928\text{-}2524\text{ nm}$) foi utilizado para adquirir imagens do músculo *Longissimus* de bovinos Nelore. As imagens foram processadas sendo selecionada a região de interesse e extraídas as informações espectrais. Todos os modelos testados foram executados utilizando espectros completos e posteriormente, foram reavaliados, utilizando espectros parciais selecionados com base nos comprimentos de onda considerados mais importantes. Os modelos com melhor desempenho obtiveram uma acurácia geral de 89,8%; 84,8% e 93,6% na classificação das amostras nos atributos maciez, maturação e pH, respectivamente. Os resultados demonstram que o sistema de imagem hiperespectral pode ser considerado uma tecnologia viável para classificação de características qualitativas da carne de bovinos Nelore.

Palavras-chave: análise multivariada, qualidade de carne, maciez, maturação, pH

Abstract

NUBIATO, K.E.Z. **Hyperspectral imaging system to classify qualitative traits of Nellore cattle beef**. 2016. 102p. PhD Thesis – College of Animal Science and Food Engineering, University of São Paulo, Pirassununga, 2016.

The beef classification as its qualitative traits is extremely important for beef industry to provide the standardization of the commercial product and that it can be allocated to specific market. Thus, the use of techniques that can identify these traits and classify them quickly, accurately and without destroying the product, it is essential. The aim of this study was to evaluate the accuracy in the classification of the tenderness of Nellore beef aged for 7, 14, 21 days or not aged and classification of aging time and pH using a bench-top hyperspectral imaging system. A hyperspectral imaging system ($\lambda = 928\text{-}2524\text{ nm}$) was used to collect images of the *Longissimus* of Nellore cattle. The images were processed, being selected region of interest and extracted spectra image. All models tested were performed using full spectra and subsequently were assessed using partial spectra selected according to the wavelengths considered more important. The models with better performance achieved an overall accuracy of 89.8%; 84.8% and 93.6% in the classification of samples in the attributes tenderness, aging and pH, respectively. The results demonstrate that the hyperspectral imaging system may be considered a viable technology for beef qualitative traits classification.

Keywords: aging, meat quality, multivariate analysis, pH, tenderness

LISTA DE TABELAS

Tabela 1. Principais diferenças entre imagens, espectroscopia e técnicas de imagem hiperespectral.	26
Tabela 2. Classes e valores para classificação das características qualitativas pH, tempo de maturação e maciez.	44
Tabela 3. Comprimentos de onda selecionados para cada transformação aplicada.	50
Tabela 4. Número de fatores (variáveis latentes) usados para gerar o modelo LDA para os espectros das amostras maturadas por 0, 7, 14 e 21 dias usadas para classificar a força de cisalhamento (maciez) das amostras maturadas por 0, 7, 14 e 21 dias.	55
Tabela 5. Acurácia geral da classificação da maciez (macia e dura), de acordo com o tempo em que espectros e força de cisalhamento (WBSF) foram medidos.	58
Tabela 6. Porcentagem de amostras corretamente classificadas como macias de acordo com o tempo em que os espectros e força de cisalhamento (WBSF) foram medidos.	60
Tabela 7. Porcentagem de amostras corretamente classificadas como duras de acordo com o tempo em que os espectros e força de cisalhamento (WBSF) foram medidos.	61
Tabela 8. Classificação dos tempos de maturação do modelo linear discriminante para a transformada de absorbância com a 1ª derivada.	64
Tabela 9. Classificação dos tempos de maturação do modelo linear discriminante para a transformada de absorbância com a 2ª derivada.	65
Tabela 10. Acurácia geral da classificação dos tempos de maturação.	65
Tabela 11. Classificação dos valores de pH usando o modelo linear discriminante com as transformadas de reflectância e absorbância com a 2ª derivada.	66
Tabela 12. Acurácia geral da classificação do pH.	67

LISTA DE FIGURAS

Figura 1. Imagem hiperespectral do músculo <i>Longissimus</i> evidenciando as assinaturas espectrais dos <i>pixels</i> de músculo e gordura.	29
Figura 2. Captura da imagem no sistema de imagem hiperespectral.	37
Figura 3. Fluxograma do processo de análise das imagens hiperespectrais. ..	38
Figura 4. Representação do espectro da imagem e sua apresentação no 39° comprimento de onda antes da segmentação.	40
Figura 5. Representação do espectro da imagem e sua apresentação no 145° comprimento de onda antes da segmentação.	41
Figura 6. Segmentação da imagem.	41
Figura 7. Média dos espectros para amostras Macia e Dura – Reflectância.	47
Figura 8. Média dos espectros para amostras Macia e Dura - Reflectância + 1ª Derivada.	48
Figura 9. Média dos espectros para amostras Macia e Dura - Reflectância + 2ª Derivada.	48
Figura 10. Média dos espectros para amostras Macia e Dura – Absorbância.	49
Figura 11. Média dos espectros para amostras Macia e Dura - Absorbância + 1ª Derivada.	49
Figura 12. Média dos espectros para amostras Macia e Dura - Absorbância + 2ª Derivada.	50
Figura 13. Distribuição dos valores de <i>Warner-Bratzler shear force</i> (WBSF) das amostras de carne bovina (n = 345).	52
Figura 14. Distribuição dos valores de pH das amostras de carne bovina (n = 78). Amostras normais < 6; DFD ≥ 6.	53
Figura 15. Média dos espectros com base no tempo de maturação - Reflectância.	97
Figura 16. Média dos espectros com base no tempo de maturação – Reflectância + 1ª Derivada.	97
Figura 17. Média dos espectros com base no tempo de maturação – Reflectância + 2ª Derivada.	98

Figura 18. Média dos espectros com base no tempo de maturação - Absorbância.	98
Figura 19. Média dos espectros com base no tempo de maturação – Absorbância + 1ª Derivada.	99
Figura 20. Média dos espectros com base no tempo de maturação – Absorbância + 2ª Derivada.	99
Figura 21. Média dos espectros com base nos valores de pH – Reflectância.	100
Figura 22. Média dos espectros com base nos valores de pH – Reflectância + 1ª Derivada.	100
Figura 23. Média dos espectros com base nos valores de pH – Reflectância + 2ª Derivada.	101
Figura 24. Média dos espectros com base nos valores de pH – Absorbância.	101
Figura 25. Média dos espectros com base nos valores de pH – Absorbância + 1ª Derivada.	102
Figura 26. Média dos espectros com base nos valores de pH – Absorbância + 2ª Derivada.	102

SUMÁRIO

1. Introdução	15
2. Revisão bibliográfica.....	17
2.1 A Raça Nelore	17
2.2 Consumidor	18
2.3 Características indicadoras da qualidade da carne.....	20
2.3.1 Potencial hidrogeniônico (pH)	20
2.3.2 Maturação	21
2.3.3 Maciez	23
2.4 Métodos de avaliação da qualidade da carne	25
2.5 Sistema de imagem hiperespectral	27
2.6 Aplicações do Sistema de Imagem Hiperespectral na avaliação da qualidade da carne	30
3. Objetivo geral.....	33
3.1 Objetivos específicos.....	33
4. Material e métodos	34
4.1 Amostras	34
4.2 Coleta de amostras	34
4.3 Análises qualitativas	35
4.3.1 Potencial hidrogeniônico	35
4.3.2 Força de cisalhamento	35
4.4 Aquisição das imagens.....	36
4.5 Processamento da imagem hiperespectral	37
4.5.1 Calibração, segmentação e extração dos dados espectrais das imagens 38	
4.5.2 Análise do dado espectral e modelos de classificação	42
4.5.3 Seleção do comprimento de onda ótimo.....	46
4.5.4 Análise do dado espectral reduzido e modelos de classificação	51
5. Resultados e Discussão	52
5.1 Características das amostras	52
5.2 Performance dos modelos de classificação de maciez.....	54
5.3 Performance dos modelos de classificação dos tempos de maturação..	64

5.4	Performance dos modelos de classificação do pH.....	66
6.	Conclusões	69
7.	Considerações Finais	70
8.	Referências bibliográficas.....	71
9.	APÊNDICES	83
	Apêndice 1- Matrizes de Confusão para o Espectro Parcial (Maciez).....	83
	Apêndice 2 - Matrizes de Confusão para o Espectro Completo (Maciez)	88
	Apêndice 3 - Matrizes de Confusão para o Espectro Completo (Tempos de Maturação)	93
	Apêndice 4 - Matrizes de Confusão para o Espectro Parcial (Tempos de Maturação).....	94
	Apêndice 5 - Matrizes de Confusão para o Espectro Parcial (pH).....	95
	Apêndice 6 - Matrizes de Confusão para o Espectro Completo (pH)	96
	Apêndice 7 – Gráficos para seleção de comprimento de onda para os tempos de maturação	97
	Apêndice 8 – Gráficos para seleção de comprimento de onda para os valores de pH.....	100

1. Introdução

Os interesses na qualidade da carne são movidos pela intenção de fornecer ao consumidor um produto de alta qualidade (SEPÚLVEDA *et al.*, 2011; ELMASRY; SUN, 2010). Nesse sentido, o fornecimento de produtos que atendam às exigências dos consumidores como: Coloração, maciez, sabor e odor, adequados; é um ponto crítico para a indústria da carne, pois tem um impacto direto na rentabilidade (TROY; KERRY, 2010).

A carne *in natura* possui características altamente variáveis, que não são controladas durante a comercialização. Essa variabilidade provém de diferenças, tanto na produção animal quanto no processamento da carne, o que impõe grande pressão sobre a indústria de fabricação de alimentos para garantir a qualidade do produto (COZZOLINO *et al.*, 2002). Este fator é agravado quando a indústria é incapaz de caracterizar, de forma satisfatória, esse nível de qualidade e não pode, portanto, comercializar seus produtos com um nível de qualidade certificada (DAMEZ; CLERJON, 2008).

Para isso, é fundamental para a indústria avaliar com precisão os atributos de qualidade da carne, que podem ser obtidos por meio do uso de técnicas modernas de avaliação da qualidade (HERRERO, 2008). Nesse sentido, a ciência e a inovação desempenham um papel muito importante, fornecendo informações para a indústria para que a mesma possa se adequar visando atender as preocupações e expectativas do consumidor (TROY; KERRY, 2010).

Várias tecnologias têm sido utilizadas com o objetivo de avaliar características indicadoras da qualidade da carne, buscando sua padronização para disponibilizar aos consumidores produtos com qualidade constante. Além disso, essas informações têm sido disponibilizadas para todos os segmentos da

cadeia produtiva, para que esses possam orientar seus sistemas produtivos, visando atender essas expectativas do consumidor.

Recentemente, o sistema de imagens hiperespectrais tem sido utilizado como uma ferramenta para prever e classificar características indicadoras da qualidade da carne, com resultados promissores. No entanto, mais estudos são necessários para avaliar a viabilidade de utilização dessa tecnologia bem como de sua acurácia em prever e classificar atributos de qualidade da carne.

2. Revisão bibliográfica

2.1 A Raça Nelore

A introdução das raças zebuínas (*Bos taurus indicus*) no Brasil, teve início nas primeiras décadas do século vinte até 1962. Desde então, a população zebuína teve um crescimento significativo no Brasil (SCHENKEL et al., 2002), sendo iniciados trabalhos de seleção que colocaram mais ênfase no estabelecimento de um padrão racial bem definido, priorizando características produtivas (EUCLIDES FILHO et al., 2000).

Dentre as raças zebuínas trazidas para o Brasil, o Nelore foi a que teve maior aceitação e expansão após as importações da Índia (LIMA, 1989). Essa expansão foi uma consequência dos elevados índices de desempenho reprodutivo e produtivo alcançados pelo Nelore em climas tropicais (OLIVEIRA; MAGNABOSCO; BORGES, 2002).

De acordo com a ABCZ (2016), de 1939 a 2015 a raça Nelore representa mais de 75% dos registros de nascimento (RGN) e mais de 68% dos registros definitivos (RGD) de zebuínos no Brasil.

De forma geral, tanto os animais da raça Nelore altamente selecionados, como aqueles criados em sistema extensivo, superam os animais de outras raças zebuínas, no que se refere à resistência, rusticidade, prolificidade, precocidade e produtividade (SANTIAGO, 1983).

As características da raça Nelore têm gerado bons índices de produção de carne, o que torna a raça de extrema importância para mercado de produção de bovinos de corte no Brasil.

2.2 Consumidor

No ano de 2014, cerca de 27 milhões de bovinos foram abatidos apenas no Brasil e mais de 1,5 milhões de toneladas de carne bovina foram exportadas para 148 países, sendo que deste montante mais de 1,2 milhões de toneladas corresponde a carne *in natura* (ABIEC, 2014).

O aumento no consumo de carne bovina é perceptível no decorrer dos anos, onde o consumo de carne está diretamente relacionado ao poder aquisitivo dos consumidores, ou seja, o aumento da renda *per capita* implica em um aumento no consumo de carne (DELGADO *et al.*, 1999), e consequentemente elevando a exigência por produtos de boa qualidade oferecidos de forma constante. No mercado globalizado, a satisfação total das exigências dos consumidores não é opcional, e sim requisito básico para o crescimento e desenvolvimento de qualquer organização.

Nos últimos anos, os aspectos relacionados à segurança alimentar e de preservação do meio ambiente têm adquirido um maior grau de importância na avaliação da “qualidade percebida” pelos consumidores. Concomitantemente, a qualidade sensorial da carne também ocupa posição de destaque. Segundo Dalari (2007 – comunicação pessoal)¹, em pesquisa realizada com consumidores brasileiros, 73-74% deles consideram a aparência geral da carne (cor e frescor) como o principal fator na decisão de compra, seguida por higiene e limpeza do estabelecimento (60-65%) e qualidade da carne (58-59%), entre

¹ DALARI, M. Demandas do consumidor e como o varejo vê o mercado. In: INTERNATIONAL MEAT CONFERENCE, São Paulo, 2007.

outros. Entre os aspectos de qualidade estão: a cor (63%), o frescor (52%), o teor de gordura (34%), a maciez (33%) e a procedência (23%). Também, Felício (1998) descreveu que os consumidores escolhem a carne com base na experiência anterior, sendo influenciados por fatores como cor da carne, quantidade e distribuição da gordura, firmeza, entre outros.

As exigências de qualidade atuais do mercado consumidor levam a necessidade de uma produção eficiente e de melhor qualidade, com abate de animais com características adequadas, ou seja, maior proporção de músculo, menor proporção de osso e quantidade ideal de gordura, às novas exigências dos consumidores, alavancando a produção animal em nível nacional e internacional.

Os aspectos qualitativos da carne bovina são então, importantes para os consumidores. Porém existem diferenças nas características de qualidade para diferentes raças, especialmente pelo uso de animais *Bos indicus*. Diversos estudos no Brasil foram conduzidos para avaliar essas variações, e as conclusões gerais convergem para a existência de influência da raça (e também do sexo) na qualidade da carne bovina (HADLICH *et al.*, 2006; BONIN, 2008). Essa diferenciação qualitativa pode ser determinada por fatores como palatabilidade, cor, capacidade de retenção de água e valor nutricional, sendo que a importância com que esses fatores são descritos na literatura podem variar tanto em diferentes músculos e carcaças como em diferentes raças e espécies (HOLLUNG *et al.*, 2007).

É notório que a maioria do consumidor moderno de carne bovina é mais bem informado e exigente quanto aos aspectos qualitativos da carne que adquire, não bastando apenas ter informações como o sexo do animal ou fazer

uma avaliação rápida dos aspectos de coloração. Este também busca informações sobre a qualidade física, química e sensorial do produto a ser consumido, além de aspectos ambientais e humanitários aos quais os animais foram submetidos na cadeia produtiva.

2.3 Características indicadoras da qualidade da carne

2.3.1 Potencial hidrogeniônico (pH)

O pH do tecido muscular de um animal vivo é praticamente neutro (7,2) (HOCQUETTE *et al.*, 1998). Quando o animal é abatido, ocorrem variações fisiológicas que causam uma alteração desse pH. Resumidamente, após o abate o músculo sofre uma privação do fornecimento de oxigênio que resulta uma alteração metabólica com a utilização do glicogênio de reserva para geração de energia, com consequente formação de ácido lático (MONIN, 1988). Esse processo ocorre enquanto houver glicogênio, resultando na redução do pH até à interrupção dos fenômenos glicolíticos ou à inativação das enzimas que regulam o metabolismo muscular (LAWRIE, 2005). Valores de pH final (após 24 horas) de aproximadamente 5,4 a 5,5 podem ser considerados normais na carne de mamíferos (GARRIDO *et al.*, 2005).

Diversos fatores podem afetar o declínio do pH das carcaças após o abate, como o sexo, a espécie, a raça, a idade, a alimentação, o estado nutricional, o estresse pré-abate e a temperatura de resfriamento (AZEVEDO, 2004; McGEEHIN *et al.*, 2001).

A redução do pH, junto com outras mudanças bioquímicas, e a queda da temperatura, durante o resfriamento das carcaças, levam ao desenvolvimento do *rigor mortis*. O *rigor mortis* é descrito como o enrijecimento da carcaça e

ocorre junto com as mudanças no período *post mortem*, afetando as fibras musculares (GREASER; GUO, 2012).

Segundo Roça (2013), para bovinos, normalmente a glicólise se desenvolve lentamente após o abate, sendo que o pH inicial (imediatamente após o abate) em torno de 7,0 cai para 6,4 – 6,8 após 5 horas e para 5,5 – 5,9 após 24 horas. Porém, caso ocorra deficiência de glicogênio, o pH permanece, após 24 horas, acima de 6,2, resultando em uma carne de cor escura e com aparência firme e seca, também conhecida como DFD (*dark, firm, dry* ou *dark-cutting*).

O pH final do músculo, após 24 horas *post mortem*, é outro fator que também exerce influência sobre vários aspectos na qualidade e na conservação da carne (KORKEALA *et al.*, 1986). O estresse do animal por período prolongado ou intenso exercício muscular durante o pré-abate causa redução nos níveis de glicogênio, elevando o pH da carne (WATANABE *et al.*, 1996). Nestas condições, haverá maior possibilidade de crescimento microbiano na carne, diminuindo o período de conservação sob refrigeração (MILLER, 2001). Além disso, existe uma relação direta entre pH final e maciez da carne, em que o aumento de pH final de 5,5 para 6,0 diminui a maciez da carne cozida, resultado do processo de formação da carne DFD (WATANABE *et al.*, 1996).

2.3.2 Maturação

Koohmaraie e Gessink (2006) afirmaram que os consumidores pagam mais por produtos cárneos que possuam características de acordo com suas preferências. Visto que, a pouca maciez da carne é uma das causas mais

comuns de não aceitação, a maturação se torna alternativa para aumentar a maciez da carne.

O processo de maturação tem sido utilizado em vários mercados, como no americano, em que o tempo varia de 10 a 14 dias de maturação, ou no Brasil, em que o tempo de maturação dura entre 14 a 21 dias. Essa diferença no tempo de maturação está associada a genética dos bovinos, já que em outros países, como nos Estados Unidos, a utilização de raças taurinas, permite a utilização de menor tempo de maturação devido à maior eficácia do processo de proteólise nestas raças.

A literatura indica que para animais zebuínos, é necessário maior tempo para que o efeito da maturação ocorra de forma eficiente, para atender as expectativas do mercado consumidor. Porém, mesmo sendo um processo conhecido e utilizado há muitos anos, apenas recentemente estão sendo cientificamente comprovadas as transformações que ocorrem durante este processo. Entretanto, é aparente que a ação de vários complexos enzimáticos na proteólise de proteínas estruturais é determinante na maciez final (KEMP *et al.*, 2010).

Dentre os diversos complexos enzimáticos, talvez o sistema proteolítico calpaína seja o mais conhecido por desempenhar um papel central na proteólise *post-mortem* e no amaciamento da carne (KOOHMARAIE; GESSINK, 2006).

Esse sistema é formado por duas calpaínas (I e II) ativadas pelo cálcio livre e inibidas por uma outra enzima denominada calpastatina (DRANSFIELD, 1993), em que 65% da variação na maciez da carne maturada pode ser explicada pela variação na atividade da calpaína I (DRANSFIELD, 1992). Além de 24 horas *post-mortem* o nível de atividade da calpastatina estar

correlacionado com a maciez da carne maturada por 14 dias, medida pela força de cisalhamento ($r=0,66$) (SCHACKELFORD *et al.*, 1993).

2.3.3 Maciez

A maciez é um fator qualitativo que afeta as características sensoriais da carne, sendo considerado o atributo mais importante após a compra (KOOHMARAIE *et al.*, 1990; VEISETH; KOOHMARAIE, 2001), podendo ser definida como a facilidade de mastigar a carne com sensações de penetração e corte, resistência à ruptura e presença de resíduo (OSÓRIO *et al.*, 2009). Esta característica está relacionada com a capacidade de retenção de água, o pH, a quantidade de gordura, as características do tecido conjuntivo e da fibra muscular.

A avaliação da maciez pode ser avaliada também por métodos subjetivos que envolvem painéis de provadores ou de consumidores, ou por métodos objetivos. A força necessária para cisalhar um corte é uma das grandezas mais utilizadas para avaliar de forma objetiva a maciez da carne. O método mais utilizado é o de *Warner-Bratzler*, que mede a força necessária para cisalhar uma amostra de carne de 1 cm de diâmetro no sentido transversal da carne, sendo que quanto maior a força em kgf, menos macia será a carne (ALVES *et al.*, 2005).

Quando o assunto é carne bovina, 50% dos consumidores dos Estados Unidos relataram que a maciez é a característica de qualidade mais importante (HOLLUNG; VEISETH-KENT, 2012), estando diretamente ligada à satisfação de consumidores e, conseqüentemente, ao aumento ou diminuição do consumo de produtos cárneos. A demanda por qualidade é uma realidade notável, pois a inconsistência na maciez gera problemas de comercialização para a cadeia

produtiva. Desta forma, a maciez é considerada por muitos a característica central da ciência da carne e muitas pesquisas têm sido desenvolvidas durante as últimas décadas para entender o que pode causar as variações nessa característica.

Ao considerar a fisiologia do músculo destaca-se que a maciez da carne é resultado da contribuição de dois principais componentes musculares, sendo eles o tecido conjuntivo e a perda no *post mortem* da integridade estrutural do sarcômero, principal aparato de contração do músculo esquelético (SAWDY *et al.*, 2004).

Sendo assim, a fase de amaciamento da carne tem recebido cada vez mais atenção na ciência da carne, sendo que o amaciamento é resultado de uma degradação chave das miofibrilas e proteínas associadas. Assim que algumas dessas proteínas são degradadas, a estrutura rígida das miofibrilas é enfraquecida e a carne se torna mais macia (LAWRIE, 2005). Portanto, existe um grande número de estudos em torno dos sistemas proteolíticos que fazem parte desse processo de degradação, onde as principais evidências são de que o sistema proteolítico das calpaínas desempenha o papel principal nesse processo.

Devine *et al.* (1990, apud SAÑUDO *et al.*, 1998) também sugeriram o efeito da idade na maciez da carne, onde os animais jovens apresentam carne mais macia, devido à maior solubilidade do colágeno. A maciez diminui com a idade, devido ao acúmulo e à maturação do tecido conjuntivo das fibras musculares, e também a uma menor fragmentação das miofibrilas após o abate de animais velhos (FRANDSON *et al.*, 1979; SAINZ; ARAÚJO, 2001).

A maciez também sofre influência do encurtamento das fibras musculares pelo frio, fenômeno que ocorre no pré-rigor, devido ao rápido resfriamento da carcaça, comprometendo a capacidade de algumas organelas sarcoplasmáticas em reterem o cálcio. Este é então liberado no sarcoplasma de maneira descontrolada e, na presença de ATP, resulta numa forte contração. A atividade contrátil produz o encurtamento das fibras, reduzindo a maciez da carne (DABÉS, 2001).

Segundo Koohmaraie (1995) a inconsistência na maciez da carne bovina, do ponto de vista do consumidor, é um dos maiores problemas que desafiam a indústria e a solução desse problema tem sido uma das principais preocupações da indústria da carne. Ainda de acordo com o mesmo autor, a inconsistência na maciez da carne deve-se a uma combinação da falta de habilidade de produzir rotineiramente carne macia e, talvez, mais importante, falta de habilidade em identificar carcaças que produzam carne dura e classificá-las adequadamente.

2.4 Métodos de avaliação da qualidade da carne

É fundamental que os produtos com características distintas sejam corretamente identificados pela indústria, de modo que esses possam ser manuseados e comercializados separadamente de acordo com as suas características específicas. Uma das formas de se avaliar estes atributos é por meio do uso de métodos considerados tradicionais como a colorimetria, a força de cisalhamento, entre outros que apesar de serem utilizados como forma de abastecimento de bancos de dados de métodos mais modernos, são demorados, destrutivos e estão associados com inconsistência e variabilidade. Por isso, busca-se a utilização de técnicas não-invasivas para uma identificação

rápida das propriedades da carne, a fim de melhorar o controle e classificação do produto. Para isso, existem diversas técnicas com fundamentos em imagem, espectroscopia e imagem associado à espectroscopia, cada qual com suas vantagens e desvantagens (Tabela 1).

Tabela 1. Principais diferenças entre imagens, espectroscopia e técnicas de imagem hiperespectral.

Recursos	Imagem	Espectroscopia	Imagem Hiperespectral
Informação espacial	X	-	X
Informação espectral	-	X	X
Informação multi-constituente	-	X	X
Construção de imagens químicas	-	-	X
Flexibilidade da extração da informação espectral	-	-	X

Fonte: Adaptado de Da-Wen Sun, 2010.

Existem diversas técnicas não-invasivas que podem ser utilizadas para avaliar as características qualitativas da carne, como a ressonância magnética nuclear, que é considerada uma técnica de referência, e pode ser utilizada em substituição a dissecação completa, por ser mais rápida, prática e precisa para medição da composição corporal (BAULAIN-NEUSTADT *et al.*, 2004). Outro método é a tomografia computadorizada, que realiza um diagnóstico por imagem por meio da radiação-x permitindo a reprodução de uma secção do corpo. Nesta técnica, as imagens apresentam profundidade, permitindo “enxergar” todas as estruturas em camadas, principalmente os mineralizados (ossos), proporcionando até a delimitação de irregularidades tridimensionais, sendo

utilizado em programas de seleção genética (BROOKS, 1993; PAPAIZ; CARVALHO, 1998; PARKS, 2000; NAVAJAS, *et al.*, 2007).

Outra importante técnica é a espectroscopia de infravermelho próximo (NIR), que ganhou aceitação abundante para a análise rápida de uma grande variedade de produtos alimentares, podendo ser usado para a análise de múltiplos atributos simultaneamente (KLAYPRADIT *et al.*, 2011). Porém, a distribuição da composição química de uma amostra não pode ser alcançada através desta técnica porque os instrumentos convencionais de espectroscopia NIR são considerados instrumentos de varrimento de base que proporcionam um espectro da amostra alvo, sem dar qualquer informação espacial.

Outra opção é o sistema de imagem hiperespectral, que vem se desenvolvendo como um método não invasivo para inspeção de carcaças e carne, podendo ser utilizado para avaliação de características físicas, identificação e quantificação de componentes químicos, assim como a sua localização e distribuição espacial simultaneamente (BELK *et al.*, 2000; VOTE *et al.*, 2003; HOPKINS *et al.*, 2004).

2.5 Sistema de imagem hiperespectral

A imagem hiperespectral é uma tecnologia analítica emergente, sem contato e não destrutiva que combina imagens digitais convencionais e espectroscopia em um único sistema. No entanto, esta técnica vai além da aquisição convencional de informações espectrais e espaciais de um objeto simultaneamente.

A técnica de imagem consiste na aquisição de informações de dados espaciais e temporais a partir de objetos usando uma câmera digital, enquanto

a espectroscopia consiste em adquirir as características espectrais de um objeto para descrever intensidades de luz que emergem de suas moléculas em diferentes comprimentos de onda e, assim, proporcionar uma impressão digital precisa desse objeto. Uma vez que os dados de imagem são considerados duas dimensões, adicionando uma nova dimensão de informação “espectro”, os dados de imagem hiperespectral podem ser percebidos como um cubo de dados (*data cube*) tridimensional (CHAO *et al.*, 2001).

Sendo assim, o sistema fornece imagens de uma forma tridimensional (3-D) denominado “hipercubo” que fornece informação espacial, juntamente com a informação espectral para cada pixel ou linha de pixels na imagem (Figura 1). O hipercubo é criado quando centenas de imagens individuais da escala de cinza são empilhadas umas sobre as outras, sendo que cada imagem no hipercubo contém uma enorme quantidade de informações sobre o objeto analisado.

Figura 1. Imagem hiperespectral do músculo *Longissimus* evidenciando as assinaturas espectrais dos *pixels* de músculo e gordura.

Fonte: DA-WEN SUN, 2010.

Essas informações podem ser utilizadas para caracterizar o objeto de forma mais confiável do que a imagem tradicional (KUMAR; MITTAL, 2009; PALLOTTINO *et al.*, 2010; QUEVEDO *et al.*, 2010) ou técnicas espectroscópicas (QUEVEDO; AGUILERA, 2010; LIU *et al.*, 2010; KLAYPRADIT *et al.*, 2011). A combinação de imagens e espectroscopia gera uma imagem hiperespectral, possibilitando determinar as características físicas e químicas de um objeto, bem como as suas distribuições espaciais (ELMASRY *et al.*, 2008; QIAO *et al.*, 2007a; MENESATTI *et al.*, 2009).

2.6 Aplicações do Sistema de Imagem Hiperespectral na avaliação da qualidade da carne

O crescimento comercial da técnica de imagens hiperespectrais ocorre pela sua capacidade para resolver alguns problemas de aplicação, tais como aqueles associados com o monitoramento industrial e controle de processos, diagnóstico, inspeção e avaliação relacionados com a qualidade, o que torna a utilização dessa técnica em um campo promissor na pesquisa para avaliação não-destrutiva de produtos agrícolas e alimentares, incluindo a qualidade da carne (CLUFF *et al.*, 2008; KONDA NAGANATHAN *et al.*, 2008a, 2008b).

A imagem hiperespectral pode ser usada para identificar um determinado tipo de carne (QIAO *et al.*, 2007a, 2007b), como carnes provenientes de diferentes espécies, diferentes cortes ou graus de acabamento diferenciados, que as tornam mais valiosas para os consumidores do que outras (ALOMAR *et al.*, 2003).

Algumas outras aplicações potenciais importantes incluem a inspeção geral e detecção de contaminantes em diferentes produtos cárneos (CHAU *et al.*, 2009; KIM *et al.*, 2004; WOLD *et al.*, 2006), além de poder ser utilizada como uma ferramenta de autenticação, a fim de evitar a fraude, bem como para estimar a composição química com uma precisão aceitável e mesmo para detectar aspectos de manipulação do produto.

As imagens hiperespectrais já foram aplicadas em produtos cárneos, para detecção de tumores em carcaças de frangos (PARK *et al.*, 2007; NAKARIYAKUL; CASASENT, 2008; KONG *et al.*, 2004), classificação de qualidade da carne suína (QIAO *et al.*, 2007a, b, c), avaliação da maciez da

carne bovina (KONDA NAGANATHAN *et al.*, 2008a, b) e avaliação da qualidade de peixes (ELMASRY; WOLD, 2008; SIVERTSEN *et al.*, 2009).

Elmasry *et al.* (2012) utilizaram um sistema de imagem hiperespectral para predição dos atributos cor, pH e maciez da carne de bovinos, e relataram um coeficiente de determinação na calibração de 89% e 83% para os índices L* e b* respectivamente, e 83% para pH e 91% para força de cisalhamento, e um coeficiente de determinação na validação cruzada de 0,88; 0,81; 0,73 e 0,83 respectivamente, caracterizando o modelo de regressão com boa precisão para a predição de quase todos os atributos avaliados.

Kamruzzaman *et al.* (2011) compararam um sistema de imagem hiperespectral com um sistema de visualização computadorizado e com o colorímetro Minolta para discriminação dos músculos *Longissimus dorsi*, *Semitendinosus* e *Psoas Major* encontrou 100% de precisão geral para a técnica de imagem hiperespectral, enquanto para as técnicas de visão computadorizada e colorímetro a acurácia foi de apenas 81,9% e 89,5% respectivamente.

Na indústria da carne, a avaliação e controle da qualidade ainda são realizados manualmente, o que é trabalhoso, caro, demorado e sujeito a erros. Sendo assim, a indústria de processamento de carne pode ser beneficiada pela utilização de métodos analíticos sem contato, não-destrutivos, rápidos, precisos e eficientes para a avaliação da carne e seus produtos, entre os quais o sistema de imagem hiperespectral se enquadra.

Portanto, o desenvolvimento de um sistema de avaliação de qualidade com base nessa tecnologia para avaliar as características de qualidade da carne e garantir a sua autenticação traria benefícios econômicos para a indústria da

carne, aumentando a confiança dos consumidores na qualidade dos produtos cárneos.

3. Objetivo geral

Avaliar o potencial de utilização do sistema de imagem hiperespectral para classificação de características relacionadas à qualidade da carne de bovinos Nelore.

3.1 Objetivos específicos

- Avaliar a viabilidade de utilização de um sistema de imagem hiperespectral para classificação da maciez da carne de bovinos Nelore maturadas por diferentes períodos;
- Avaliar a viabilidade de utilização de um sistema de imagem hiperespectral para classificação dos tempos de maturação da carne de bovinos Nelore;
- Avaliar a viabilidade de utilização de um sistema de imagem hiperespectral para classificação do pH da carne de bovinos Nelore.

4. Material e métodos

4.1 Amostras

As amostras utilizadas foram provenientes de 96 bovinos Nelore de um confinamento experimental realizado na Faculdade de Zootecnia e Engenharia de Alimentos da Universidade de São Paulo, em Pirassununga/SP/Brasil.

Os animais foram confinados por um período total de 100 dias, recebendo uma dieta com 24% de volumoso e 76% de concentrado, a qual não interfere nas análises subsequentes dos espectros.

4.2 Coleta de amostras

Os animais foram divididos em dois grupos e abatidos em duas semanas consecutivas.

O abate foi realizado de acordo com procedimentos humanitários, conforme exigido pela legislação brasileira. Os animais foram insensibilizados utilizando-se atordoamento com pistola pneumática penetrante e imediatamente após foi realizada a sangria pela seção dos grandes vasos do pescoço. Em seguida foi realizada a esfolagem, evisceração e lavagem das carcaças e o resfriamento das mesmas.

Quarenta e oito horas após o abate, a meia-carcaça direita de cada animal foi dividida na região entre a 12ª e a 13ª costelas, de onde foram retiradas quatro amostras do *Longissimus* (2,5 cm de espessura cada), no sentido caudocranial, a partir da 12ª costela, para realização de análises de qualidade instrumental e aquisição das imagens.

4.3 Análises qualitativas

A partir da coleta das amostras, as mesmas foram identificadas individualmente e embaladas à vácuo e em seguida maturadas (4°C) por 0, 7, 14 e 21 dias.

4.3.1 Potencial hidrogeniônico

O pH e a temperatura do músculo *Longissimus* na região entre a 12ª e a 13ª costelas, foram determinados 24 h após o abate utilizando-se um peagâmetro de sonda, portátil modelo AK 86 (AKSO®).

4.3.2 Força de cisalhamento

As amostras foram preparadas de acordo com o protocolo da AMSA (AMSA, 1995), em que um termopar foi inserido no centro geométrico de cada amostra para monitorar a temperatura interna. As amostras foram cozidas em forno elétrico até a temperatura de 40° C, em seguida as amostras foram viradas e cozidas até a temperatura de 71° C. As amostras foram resfriadas em temperatura ambiente e foram envolvidas em película de plástico e resfriadas em um refrigerador (2 à 5° C) durante 24 h. A força de cisalhamento foi determinada a partir de seis repetições (1,27 cm de diâmetro) retiradas seguindo o sentido longitudinal das fibras e cisalhadas seguindo o sentido transversal das fibras, utilizando equipamento WBSF (*G-R Manufacturing Co., Manhattan, KS, USA*) equipado com uma lâmina *Warner-Bratzler*. O valor de WBSF foi dado pela média dos valores das seis medições e expresso em N, sendo considerado para a classificação da maciez que amostras com $WBSF \leq 39.23$ N foram macias e $WBSF > 39.23$ N foram duras (LAWRIE, 2005).

4.4 Aquisição das imagens

As amostras foram transportadas em caixa térmica para o laboratório do Instituto de Química / Unicamp, onde as imagens hiperespectrais foram coletadas, nas amostras *in natura*, utilizando-se sistema de imagem hiperespectral *SisuCHEMA SWIR hyperspectral camera (SPECIM Spectral Imaging Ltd, FIN-90571 Oulu, Finland)* no intervalo de 928-2524 nm, 10 nm de resolução espectral e 320 pixels por linha de escaneamento. A câmera é configurada para escaneamento em linha e possui uma fonte de tungstênio-halogênio, detectores de arranjo bidimensional com 256 comprimento de ondas (bandas) e *software* Evince® (UmBio AB, Suécia) previamente calibrado para aquisição das imagens (Figura 2).

As amostras foram retiradas das embalagens e deixadas expostas ao ambiente por 30 min para que ocorresse a oxigenação da mioglobina, ao mesmo tempo a superfície das amostras foram secas com um papel toalha, evitando qualquer tipo de interferência na aquisição das imagens devido ao acúmulo de umidade na superfície das amostras.

Em seguida, as amostras foram colocadas na esteira de translação e movimentadas para atingir o “campo de visão” do equipamento, sendo a velocidade limitada pela velocidade da câmera, onde foi realizada a leitura (*scanning*) da amostra, mantendo o tempo de exposição da amostra à câmera em torno de 2,2 ms à uma lente de 100 mm. As imagens foram armazenadas em um computador utilizando o *software* Evince® (UmBio AB, Suécia) para posterior tratamento e interpretação.

Figura 2. Captura da imagem no sistema de imagem hiperespectral.

Fonte: Própria autoria.

4.5 Processamento da imagem hiperespectral

A calibração, seleção da região de interesse e extração dos dados espectrais foram feitas no *software* MATLAB (The MathWorks Inc., Natick, MA). O desenvolvimento dos modelos de classificação das características qualitativas foi desenvolvido no *software* Unscrambler® X (CAMO Software AS) como apresentado no fluxograma a seguir (Figura 3).

Figura 3. Fluxograma do processo de análise das imagens hiperespectrais.

Fonte: Própria autoria.

4.5.1 Calibração, segmentação e extração dos dados espectrais das imagens

Anteriormente a cada aquisição de imagem hiperespectral, imagens de referência de escuro e branco foram obtidas de forma automática pelo sistema de imagem hiperespectral utilizado, seguindo a equação (Equação 1). Este processo de calibração de reflectância minimiza as variações devido a

iluminação, a resposta do sensor, e condições ambientais nas imagens hiperespectrais da carne bovina.

Em seguida, devido ao grande número de espectros referentes a grande quantidade de ruído (Figura 4 e Figura 5), as imagens calibradas foram segmentadas, selecionando-se apenas o músculo *Longissimus*, em um fundo homogêneo para destacar a principal região de interesse (ROI) na amostra, eliminando a maior quantidade possível de ruídos da imagem (Figura 6), para o procedimento de segmentação foi utilizado um algoritmo específico em MATLAB (The MathWorks Inc., Natick, MA).

$$R = \frac{R0 - D}{W - D} \quad (1)$$

Em que,

R = imagem corrigida;

R0 = imagem original;

D = referência de escuro;

W = referência de branco.

Figura 4. Representação do espectro da imagem e sua apresentação no 39º comprimento de onda antes da segmentação.

Fonte: Própria autoria.

Figura 5. Representação do espectro da imagem e sua apresentação no 145° comprimento de onda antes da segmentação.

Fonte: Própria autoria.

Figura 6. Segmentação da imagem.

Fonte: Própria autoria.

Posteriormente, as imagens segmentadas foram usadas para extração dos dados espectrais usando um algoritmo de processamento de imagem no MATLAB (The MathWorks Inc., Natick, MA).

4.5.2 Análise do dado espectral e modelos de classificação

Ainda não existe um procedimento padrão para decidir qual pré-processamento espectral aplicar e muitas vezes a única abordagem é a tentativa e erro. Neste estudo, foram implementadas técnicas de pré-processamento para analisar o impacto do ruído nos dados espectrais adquiridos a partir das amostras de carne, preservando informações químicas. Foram aplicadas as transformações de espectro associadas ou não as derivadas: reflectância, reflectância + 1ª derivada, reflectância + 2ª derivada, absorbância, absorbância + 1ª derivada e absorbância + 2ª derivada. A 1ª e 2ª derivadas foram aplicadas a fim de minimizar o espalhamento e evidenciar características espectrais, pois são capazes de compensar variações da linha de base e separar picos sobrepostos, respectivamente (BARBIN *et al.*, 2012).

As transformações foram usadas nos modelos de classificação do pH, maturação e maciez. Sendo que, na maciez foram usados também os espectros coletados do tempo 0 de maturação para classificar as amostras maturadas por 0, 7, 14 e 21 dias de maturação; espectros coletados no tempo 7 para classificar as amostras maturadas por 7, 14 e 21 dias; espectro coletado no tempo 14 para classificar as amostras maturadas por 14 e 21 dias; espectro coletado no tempo 21 para classificar as amostras maturadas por 21 dias.

A regressão por mínimos quadrados parciais (PLSR) é um procedimento usado para relacionar um conjunto de variáveis independentes (preditoras) com variáveis de resposta (observações). Esta técnica é particularmente eficaz na análise espectral onde o número de preditores (comprimentos de onda) é altamente correlacionado e muito maior do que o número de observações

(KAMRUZZAMAN *et al.*, 2012), reduzindo o grande número de variáveis descritoras a um pequeno conjunto de variáveis constituído por uma quantidade pequena de fatores ortogonais, comumente chamados de variáveis latentes ou fatores (BARBIN *et al.*, 2012). Após a realização do PLSR obteve-se o modelo descrito pela Equação 2:

$$Y = Xb + e \quad (2)$$

Em que:

Y = matriz de medidas instrumentais (número de amostras x 1).

X = matriz de preditores (número de amostras x comprimentos de onda).

b = matriz dos coeficientes de regressão.

e = matriz do resíduo.

Neste estudo o método de validação cruzada completo (*leave-one-out*) foi utilizado para validar os modelos PLSR. O método consiste na remoção de uma amostra (amostra teste) a partir do conjunto de dados e o modelo PLSR será então estabelecido para as amostras restantes (amostras de treinamento). Ao final, o modelo foi utilizado para prever a amostra deixada de fora. Este procedimento foi repetido para cada uma das amostras no conjunto de dados. Ao final da validação cruzada, os coeficientes de determinação da validação cruzada (R^2_{CV}) e a raiz quadrada média do erro estimado pela validação cruzada (RMSECV) foram usados para determinar o número ideal de variáveis latentes (fatores) (BARBIN *et al.*, 2012). Foram usados os maiores valores dos coeficientes de determinação da validação cruzada (R^2_{CV}) e os menores valores da raiz quadrada média do erro estimado pela validação cruzada (RMSECV) para determinar o número de fatores ideais que variavam de 1 a 7.

O PLSR foi aplicado para os conjuntos de dados espectrais (256 bandas) para cada característica de qualidade, individualmente, em todas as transformações espectrais: reflectância, reflectância + 1ª derivada, reflectância + 2ª derivada, absorbância, absorbância + 1ª derivada e absorbância + 2ª derivada.

Após a obtenção das variáveis latentes, foi realizada a técnica de Análise Discriminante Linear (LDA), que teve como objetivo classificar de forma independente, as amostras quanto às características qualitativas avaliadas, visando diminuir a probabilidade de classificação errada.

Para realização do LDA deve-se considerar que as classes possuem a mesma matriz de covariância, por isso uma função linear. Obteve-se então, uma combinação linear (função discriminante) das características observadas que apresentaram maior potencial de separação das classes (Varella, 2016).

Para esta etapa foram utilizados as variáveis latentes (fatores) correspondentes aos resultados do PLSR, que foram inseridos no modelo LDA para classificação das amostras quanto o pH, o tempo de maturação e a maciez (Tabela 2).

Tabela 2. Classes e valores para classificação das características qualitativas pH, tempo de maturação e maciez.

pH*		Tempo de Maturação				Maciez (N)**	
Normal	DFD	Dias				Macia	Dura
< 6	≥ 6	0	7	14	21	≤ 39,23	> 39,23

*Valores de referência do pH segundo Lawrie (2005).

**N = Newton (Unidade de força usada para avaliação da força de cisalhamento).
Fonte: Própria autoria.

A acurácia geral (Equação 3) é uma análise métrica comumente usada para avaliar os modelos de classificação. Mesmo a acurácia geral sendo de

grande utilidade na avaliação dos modelos de classificação, ela pode não explicar adequadamente a performance de modelos de classificação compostos por conjuntos de dados desbalanceados (Konda Naganathan *et al.*, 2015), como ocorreu em alguns tempos de maturação, em que se teve maiores ou menores proporções de amostras macias ou duras. Portanto, outras duas medidas de acurácia foram consideradas para avaliação dos modelos de classificação da maciez. Acurácia de identificação das amostras macias (Equação 4) e acurácia de identificação das amostras duras (Equação 5).

$$\frac{A + D}{(A + B + C + D)} * 100 \quad (3)$$

$$\frac{A}{(A + B)} * 100 \quad (4)$$

$$\frac{D}{(C + D)} * 100 \quad (5)$$

Em que:

A = Número de amostras macias verdadeiras corretamente preditas como amostras macias.

B = Número de amostras macias verdadeiras incorretamente preditas como amostras duras.

C = Número de amostras duras verdadeiras incorretamente preditas como amostras macias.

D = Número de amostras duras verdadeiras corretamente preditas como amostras duras.

A + B = Número total de amostras macias verdadeiras.

C + D = Número total de amostras duras verdadeiras.

$A + D$ = Número total de amostras preditas corretamente.

$A + B + C + D$ = Número total de amostras.

4.5.3 Seleção do comprimento de onda ótimo

Uma vez que os dados de imagem hiperespectral são caracterizados pela sua elevada dimensionalidade com redundância entre os comprimentos de onda contíguos, a redução de dimensão da imagem foi conduzida para acelerar o processo de análise subsequente. Na prática, a precisão do modelo com dados de alta dimensão, tais como as imagens hiperespectrais podem ser melhorados reduzindo a dimensão dos comprimentos de onda ou aumentando o número de amostras de treino.

Os comprimentos de onda mais importantes podem ser escolhidos nas regiões espectrais para os quais existe uma grande diferença nos padrões espectrais das amostras testadas, que além de reduzir significativamente o tempo de processamento, podendo melhorar a capacidade de predição do modelo (OSBORNE *et al.*, 1997). A seleção dos comprimentos de onda é importante, uma vez que algumas das variáveis podem ter informações irrelevantes ou ruído (KESKIN *et al.*, 2004).

Nesse estudo, foram obtidas as médias dos dados espectrais das amostras macias e duras, e foram plotados gráficos dos resultados (Figura 7, 8, 9, 10, 11 e 12), sendo o mesmo feito para os tempos de maturação e valores de pH. O gráfico das médias dos dados espectrais foi gerado para todas as seis transformações aplicadas no conjunto completo de comprimentos de onda (número total 256 bandas) anteriormente, em que foram selecionados os comprimentos de onda presentes nas regiões espectrais que existiam maior

diferença nos padrões espectrais das amostras testadas (OSBORNE *et al.*, 1997, Tabela 3).

Figura 7. Média dos espectros para amostras Macia e Dura – Reflectância.

Fonte: Própria autoria.

Figura 8. Média dos espectros para amostras Macia e Dura - Reflectância + 1ª Derivada.

Fonte: Própria autoria.

Figura 9. Média dos espectros para amostras Macia e Dura - Reflectância + 2ª Derivada.

Fonte: Própria autoria.

Figura 10. Média dos espectros para amostras Macia e Dura – Absorbância.

Fonte: Própria autoria.

Figura 11. Média dos espectros para amostras Macia e Dura - Absorbância + 1ª Derivada.

Fonte: Própria autoria.

Figura 12. Média dos espectros para amostras Macia e Dura - Absorbância + 2ª Derivada.

Fonte: Própria autoria.

Tabela 3. Comprimentos de onda selecionados para cada transformação aplicada.

Comprimentos de onda Selecionados (nm)	
Transformações	Reflectância
	928-1413
	Reflectância+1Derivada
	928-1080;1212-1268
	Reflectância+2Derivada
	941-973;985-1036;1136-1224
	Absorbância
	928-2524
	Absorbância+1Derivada
	1080-1212;1268-1463;1639-1733;1845-1939
	Absorbância+2Derivada
	1105-1143;1224-1388;1739-1758;1839-1883

Fonte: Própria autoria.

4.5.4 Análise do dado espectral reduzido e modelos de classificação

Usando apenas os comprimentos de onda selecionados, um novo modelo PLSR foi construído relacionando o conjunto reduzido de indicadores para as respostas medidas. Da mesma forma que os modelos de regressão anteriores utilizando os espectros completos, os resultados da validação cruzada *leave-one-out* foram usados para determinar o número ideal de variáveis latentes (fatores). Foram usados os maiores valores dos coeficientes de determinação da validação cruzada (R^2_{CV}) e os menores valores da raiz quadrada média do erro estimado pela validação cruzada (RMSECV). Todos os passos descritos foram realizados no software Unscrambler® X (CAMO Software AS).

Após a obtenção das novas variáveis latentes, foi feita novamente a técnica de Análise Discriminante Linear (LDA), que teve como objetivo identificar e classificar as amostras quanto o pH, tempos de maturação e maciez (Tabela 2).

Para esta etapa foram utilizados os fatores correspondentes aos resultados do novo PLSR, que foram inseridos no modelo LDA para classificação das amostras quanto o pH, tempos de maturação e maciez.

5. Resultados e Discussão

5.1 Características das amostras

Devido aos tempos de maturação aplicados nas amostras (0, 7, 14 e 21 dias), a variação dos valores de WBSF foi de 8,14 N a 101,01 N. Levando-se em consideração o limite dos valores de WBSF para classificação da maciez (macias $\leq 39,23$ N e duras $> 39,23$ N), dentro dos tempos de maturação a porcentagem de amostras macias e duras foram: Tempo 0 = 13,6% macia e 86,4% dura; Tempo 7 = 42,2% macia e 57,8% dura; Tempo 14 = 76,1% macia e 23,9% dura; Tempo 21 = 83,5% macia e 16,5% dura (Figura 13).

Figura 13. Distribuição dos valores de *Warner-Bratzler shear force* (WBSF) das amostras de carne bovina (n = 345).

Fonte: Própria autoria.

De forma semelhante, obteve-se um desbalanceamento das classes quanto aos valores de pH, em que o intervalo dos valores foram de 4,86 a 6,63. Levando-se em consideração o limite dos valores de pH para a classificação do mesmo (< 6 Normal e ≥ 6 DFD), tem-se que: pH 24 horas = 85,9% Normal e 14,1% DFD (Figura 14).

Deve-se considerar que houve um desbalanceamento de classes tanto para maciez quanto para pH, mas de acordo com Xue e Titterington (2008) o modelo linear discriminante é capaz de apresentar grande potencial de classificação.

Figura 14. Distribuição dos valores de pH das amostras de carne bovina ($n = 78$). Amostras normais < 6 ; DFD ≥ 6 .

Fonte: Própria autoria.

5.2 Performance dos modelos de classificação de maciez

O número de fatores (variáveis latentes) usados para gerar o modelo LDA variou de 1 a 7, determinados a partir dos maiores valores de R^2_{CV} e os menores valores de RMSECV (Tabela 4).

Tabela 4. Número de fatores (variáveis latentes) usados para gerar o modelo LDA para os espectros das amostras maturadas por 0, 7, 14 e 21 dias usadas para classificar a força de cisalhamento (maciez) das amostras maturadas por 0, 7, 14 e 21 dias.

		*Espectro (dias) – Warner Bratzler Shear Force (dias)									
		0-0	0-7	0-14	0-21	7-7	7-14	7-21	14-14	14-21	21-21
Espectro Completo	Reflectância	7	7	7	7	7	7	7	7	7	7
	Reflectância+1Derivada	6	6	6	6	7	7	7	7	7	3
	Reflectância+2Derivada	3	3	3	3	7	7	7	7	7	7
	Absorbância	7	7	7	7	7	7	7	7	7	7
	Absorbância+1Derivada	4	4	4	4	7	7	7	7	7	7
	Absorbância+2Derivada	4	4	4	4	6	6	6	7	7	7
Espectro Parcial	Reflectância	4	1	1	7	7	1	5	7	7	7
	Reflectância+1Derivada	3	1	1	6	1	1	3	3	3	3
	Reflectância+2Derivada	2	1	3	2	1	1	1	1	7	3
	Absorbância	5	1	1	5	7	3	4	7	7	7
	Absorbância+1Derivada	7	1	4	4	1	5	5	1	7	5
	Absorbância+2Derivada	2	1	7	2	1	1	1	3	7	7

*Espectro-Warner Bratzler Shear Force (WBSF) = 0-0: espectro do dia 0 classificando WBSF no dia 0; 0-7: espectro do dia 0 classificando WBSF no dia 7; 0-14: espectro do dia 0 classificando WBSF no dia 14; 0-21: espectro do dia 0 classificando WBSF no dia 21; 7-7: espectro do dia 7 classificando WBSF no dia 7; 7-14: espectro do dia 7 classificando WBSF no dia 14; 7-21: espectro do dia 7 classificando WBSF no dia 21; 14-14: espectro do dia 14 classificando WBSF no dia 14; 14-21: espectro do dia 14 classificando WBSF no dia 21; 21-21: espectro do dia 21 classificando WBSF no dia 21.

Fonte: Própria autoria.

Na Tabela 5 são apresentados os valores de acurácia geral para o modelo LDA de classificação da maciez (macia e dura), em todas as análises foi considerado como não significativo aumento menor que 2% na variação das acurácias.

Tendo apenas como fator de comparação os comprimentos de onda (espectro completo ou parcial), modelos contendo espectros completos apresentaram maiores valores de acurácia geral quando utilizadas:

- Imagens de amostras maturadas por 7 dias classificando WBSF de amostras com 14 dias de maturação (71,7%;Tabela 5);
- Imagens das amostras maturadas por 14 dias classificando WBSF de amostras maturadas pelo mesmo período (71,1%;Tabela 5).

Quando efetuado a seleção dos comprimentos de onda (espectro parcial), maiores resultados de acurácia geral foram obtidos utilizando:

- Imagens de amostras não maturadas (0 dias) classificando amostras maturadas por 7 e 14 dias (64,8% e 78,4%, respectivamente; Tabela 5);
- Imagens de amostras maturadas por 7 dias classificando WBSF de amostras maturadas pelo mesmo período (72,2%;Tabela 5);
- Imagens das amostras maturadas por 14 dias classificando WBSF das amostras com 21 de maturação (88,4%;Tabela 5);
- Imagens das amostras maturadas por 21 dias classificando WBSF das amostras com o mesmo tempo de maturação (88,6%; Tabela 5).

Entretanto, observou-se que ao utilizar amostras que não foram

maturadas para classificar WBSF de amostras com o mesmo tempo de maturação e amostras maturadas por 21 dias, a seleção dos comprimentos de onda (espectro parcial) não influenciou no resultado da classificação. O mesmo foi observado ao utilizar imagens com 7 dias de maturação classificando WBSF de amostras maturadas por 21 dias. Assim pode ser observado que a seleção dos comprimentos de onda (espectro parcial) resultou em melhores valores de acurácia geral na classificação da maciez (Tabela 5).

De forma sequencial, realizada a seleção dos comprimentos de onda (espectro parcial), agora considerando como fator de comparação apenas as transformações de espectros (refletância e absorbância) abrangendo seus respectivos pré-tratamentos (1ª e 2ª derivadas), observou-se que os maiores valores de acurácia geral, na classificação da maciez, foram obtidos quando utilizado a absorbância como transformação de espectro.

Comparando os valores de acurácia geral considerando a aplicação ou não dos pré-tratamentos, dentro da absorbância e espectro parcial, maiores valores de acurácia foram encontrados ao se utilizar os pré-tratamentos. Assim sendo, o uso dos pré-tratamentos foi eficiente para classificação da maciez.

Tabela 5. Acurácia geral da classificação da maciez (macia e dura), de acordo com o tempo em que espectros e força de cisalhamento (WBSF) foram medidos.

			*Espectro (dias) – Warner Bratzler Shear Force (dias)									
Comprimentos de Ondas (nm)			0-0	0-7	0-14	0-21	7-7	7-14	7-21	14-14	14-21	21-21
Espectro Completo	Reflectância	928-2524	90,9	59,1	70,5	76,1	61,9	66,3	78,3	61,1	85,6	80,0
	Reflectância+1Derivada	928-2524	88,6	60,2	68,2	64,7	67,4	67,4	72,8	65,6	81,1	63,3
	Reflectância+2Derivada	928-2524	79,6	55,7	67,1	63,6	59,8	66,3	65,2	66,7	78,9	71,1
	Absorbância	928-2524	89,8	62,5	70,5	69,3	64,1	71,7	77,2	68,9	78,9	81,1
	Absorbância+1Derivada	928-2524	89,8	56,8	56,8	64,8	67,4	71,7	76,1	63,3	77,8	81,1
	Absorbância+2Derivada	928-2524	86,4	61,4	62,5	71,6	63,0	66,3	75,0	71,1	71,1	85,6
Espectro Parcial	Reflectância	928-1413	84,1	63,6	62,5	76,1	71,1	62,2	76,7	65,9	84,1	82,3
	Reflectância+1Derivada	928-1080;1212-1268	77,3	63,6	60,2	76,1	65,6	61,1	72,2	65,9	71,6	74,7
	Reflectância+2Derivada	941-973;985-1036;1136-1224	81,8	64,8	75,0	64,8	67,8	62,2	57,8	61,1	76,7	74,7
	Absorbância	928-2524	88,6	63,6	62,5	73,9	72,2	58,9	73,3	67,8	77,8	86,1
	Absorbância+1Derivada	1080-1212;1268-1463;1639-1733;1845-1939	89,8	63,6	73,9	63,6	64,4	65,6	78,9	60,0	88,4	82,3
	Absorbância+2Derivada	1105-1143;1224-1388;1739-1758;1839-1883	88,6	63,6	78,4	61,4	65,6	61,1	60,0	62,2	84,4	88,6

*Espectro-Warner Bratzler Shear Force (WBSF) = 0-0: espectro do dia 0 classificando WBSF no dia 0; 0-7: espectro do dia 0 classificando WBSF no dia 7; 0-14: espectro do dia 0 classificando WBSF no dia 14; 0-21: espectro do dia 0 classificando WBSF no dia 21; 7-7: espectro do dia 7 classificando WBSF no dia 7; 7-14: espectro do dia 7 classificando WBSF no dia 14; 7-21: espectro do dia 7 classificando WBSF no dia 21; 14-14: espectro do dia 14 classificando WBSF no dia 14; 14-21: espectro do dia 14 classificando WBSF no dia 21; 21-21: espectro do dia 21 classificando WBSF no dia 21.

Fonte: Própria autoria.

Sendo assim, o modelo composto pela combinação da seleção dos comprimentos de onda (espectro parcial) associado à absorbância como transformação do espectro e a 1ª derivada como pré-tratamento foi capaz de classificar a maciez das amostras de carne bovina com uma acurácia geral de até 89,8% (0 dias classificando 0 dias; Tabela 5)

Ao identificar apenas amostras macias, o maior valor de acurácia foi obtido utilizando imagens de amostras não maturadas para classificar WBSF de amostras também não maturadas (91,7%;Tabela 6). No entanto, na classificação das amostras duras, o melhor resultado de acurácia foi observado utilizando imagens de amostras maturadas por 14 dias classificando WBSF das amostras com 21 dias de maturação (100%;Tabela 7).

Quando considerada a identificação das amostras macias e duras, os maiores valores de acurácia foram obtidos aplicando a absorbância como transformação do espectro associada à seleção dos comprimentos de onda (espectro parcial), sendo facultativo o uso dos pré-tratamentos (1ª e 2ª derivadas). Assim de maneira conclusiva, o modelo LDA obteve melhor performance tanto na identificação geral quanto na identificação de amostras macias ou duras, quando foi aplicada a seleção dos comprimentos de onda com a absorbância como transformada de espectro associados aos pré-tratamentos (1ª e 2ª derivadas).

Tabela 6. Porcentagem de amostras corretamente classificadas como macias de acordo com o tempo em que os espectros e força de cisalhamento (WBSF) foram medidos.

			*Espectro (dias) – Warner Bratzler Shear Force (dias)									
Comprimentos de Ondas (nm)			0-0	0-7	0-14	0-21	7-7	7-14	7-21	14-14	14-21	21-21
Espectro Completo	Reflectância	928-2524	83,3	61,1	74,6	75,0	65,0	67,1	77,2	65,2	84,4	79,2
	Reflectância+1Derivada	928-2524	83,3	63,9	71,6	61,8	70,0	67,1	70,9	66,7	79,2	62,3
	Reflectância+2Derivada	928-2524	83,3	61,1	65,7	63,2	60,0	67,1	64,6	66,7	79,2	71,4
	Absorbância	928-2524	83,3	63,9	70,2	68,4	60,0	71,4	76,0	73,9	79,2	79,2
	Absorbância+1Derivada	928-2524	83,3	52,8	56,7	64,5	65,0	72,9	74,7	62,3	75,3	80,5
	Absorbância+2Derivada	928-2524	83,3	61,1	61,2	72,4	65,0	65,7	73,4	69,6	70,1	84,4
Espectro Parcial	Reflectância	928-1413	83,3	63,9	59,7	74,0	68,4	58,8	76,6	65,7	81,1	83,3
	Reflectância+1Derivada	928-1080;1212-1268	91,7	63,9	56,7	76,6	65,8	57,4	71,4	65,7	68,9	72,7
	Reflectância+2Derivada	941-973;985-1036;1136-1224	91,7	66,7	73,1	63,6	71,1	58,8	55,8	58,0	76,0	72,7
	Absorbância	928-2524	83,3	63,9	59,7	72,7	68,4	60,3	71,4	66,7	77,3	86,4
	Absorbância+1Derivada	1080-1212;1268-1463;1639-1733;1845-1939	83,3	63,9	76,1	62,3	65,8	64,7	77,9	56,5	84,0	83,3
	Absorbância+2Derivada	1105-1143;1224-1388;1739-1758;1839-1883	83,3	63,9	83,6	59,7	65,8	57,4	58,4	60,9	84,0	87,9

*Espectro-Warner Bratzler Shear Force (WBSF) = 0-0: espectro do dia 0 classificando WBSF no dia 0; 0-7: espectro do dia 0 classificando WBSF no dia 7; 0-14: espectro do dia 0 classificando WBSF no dia 14; 0-21: espectro do dia 0 classificando WBSF no dia 21; 7-7: espectro do dia 7 classificando WBSF no dia 7; 7-14: espectro do dia 7 classificando WBSF no dia 14; 7-21: espectro do dia 7 classificando WBSF no dia 21; 14-14: espectro do dia 14 classificando WBSF no dia 14; 14-21: espectro do dia 14 classificando WBSF no dia 21; 21-21: espectro do dia 21 classificando WBSF no dia 21.

Fonte: Própria autoria.

Tabela 7. Porcentagem de amostras corretamente classificadas como duras de acordo com o tempo em que os espectros e força de cisalhamento (WBSF) foram medidos.

			*Espectro (dias) – Warner Shear Force (dias)									
Comprimentos de Ondas (nm)			0-0	0-7	0-14	0-21	7-7	7-14	7-21	14-14	14-21	21-21
Espectro Completo	Reflectância	928-2524	92,1	57,7	57,1	83,3	59,6	63,6	84,6	47,6	92,3	84,6
	Reflectância+1Derivada	928-2524	89,5	57,7	57,1	83,3	65,4	68,2	84,6	61,9	92,3	69,2
	Reflectância+2Derivada	928-2524	79,0	51,9	71,4	66,7	59,6	63,6	69,2	66,7	76,9	69,2
	Absorbância	928-2524	90,8	61,5	71,4	75,0	67,3	72,7	84,6	52,4	76,9	92,3
	Absorbância+1Derivada	928-2524	90,8	59,6	57,1	66,7	69,2	68,2	84,6	66,7	92,3	84,6
	Absorbância+2Derivada	928-2524	86,8	61,5	66,7	66,7	61,5	68,2	84,6	76,2	76,9	92,3
Espectro Parcial	Reflectância	928-1413	84,2	63,5	71,4	90,9	73,1	72,7	76,9	66,7	100,0	76,9
	Reflectância+1Derivada	928-1080;1212-1268	75,0	63,5	71,4	72,7	65,4	72,7	76,9	66,7	85,7	84,6
	Reflectância+2Derivada	941-973;985-1036;1136-1224	80,3	63,5	81,0	72,7	65,4	72,7	69,2	71,4	80,0	84,6
	Absorbância	928-2524	89,5	63,5	71,4	81,8	75,0	54,6	84,6	71,4	80,0	84,6
	Absorbância+1Derivada	1080-1212;1268-1463;1639-1733;1845-1939	90,8	63,5	66,7	72,7	63,5	68,2	84,6	71,4	86,7	76,9
	Absorbância+2Derivada	1105-1143;1224-1388;1739-1758;1839-1883	89,5	63,5	61,9	72,7	65,4	72,7	69,2	66,7	86,7	92,3

*Espectro-Warner Bratzler Shear Force (WBSF) = 0-0: espectro do dia 0 classificando WBSF no dia 0; 0-7: espectro do dia 0 classificando WBSF no dia 7; 0-14: espectro do dia 0 classificando WBSF no dia 14; 0-21: espectro do dia 0 classificando WBSF no dia 21; 7-7: espectro do dia 7 classificando WBSF no dia 7; 7-14: espectro do dia 7 classificando WBSF no dia 14; 7-21: espectro do dia 7 classificando WBSF no dia 21; 14-14: espectro do dia 14 classificando WBSF no dia 14; 14-21: espectro do dia 14 classificando WBSF no dia 21; 21-21: espectro do dia 21 classificando WBSF no dia 21.

Fonte: Própria autoria.

Konda Naganathan *et al.* (2008b) utilizaram o sistema imagem hiperespectral (HSI) *pushbroom* (sistema de varredura) calibrado para aquisição de imagens no intervalo de comprimento de onda de 900 a 1700 nm, com o qual foram adquiridas imagens com 243 bandas de 319 amostras do músculo *Longissimus dorsi*. Devido a presença de ruído as 15 primeiras e as 28 últimas bandas foram excluídas da análise, restando um total de 200 bandas compreendidas no intervalo de 965 a 1625 nm.

A técnica de *slice shear force* (SSF) foi utilizada para mensurar a maciez das amostras, que foram agrupadas da seguinte forma: $SSF \leq 205,80$ N foram consideradas macias; $205,80 \text{ N} < SSF < 254,80 \text{ N}$ foram consideradas intermediárias e $SSF \geq 254,80$ foram consideradas duras.

Ao avaliarem a maciez de amostras de carne bovina maturadas por 14 dias com imagens adquiridas entre 3 e 5 dias *post mortem*, utilizando a análise canônica discriminante (CDA) com validação cruzada, obtiveram uma acurácia de 77% na classificação da maciez das amostras nas 3 categorias supracitadas. Em uma nova configuração de categorias de maciez, classificando as amostras intermediárias como macias, os autores encontraram 94,5% de acurácia na classificação da maciez em apenas duas categorias (macia e dura).

Os valores de acurácia na classificação foram maiores que os obtidos neste estudo para o mesmo tempo de maturação (78,4% de acurácia utilizando imagens de amostras não maturadas classificando amostras com 14 dias de maturação). A menor precisão na classificação reportada neste trabalho pode ser justificada pela concentração de aproximadamente 20% das amostras na região de determinação da maciez (34,32 N a 44,13 N).

No entanto, em outro estudo realizado por Konda Naganathan *et al.* (2016), o autor utilizou um sistema de imagem hiperespectral *on-line* ($\lambda = 400\text{--}1000\text{ nm}$) para classificar, quanto a maciez, 274 amostras do *Longissimus* de bovinos aos 2 dias *post-mortem*. Utilizando modelo linear discriminante de Fisher com validação cruzada para classificação das amostras em reflectância. Como método de avaliação da maciez foi utilizado a técnica de WBSF, agrupando as amostras em duas classes: $\text{WBSF} \leq 44,0\text{ N}$ consideradas macias e $\text{WBSF} > 44,0\text{ N}$ consideradas duras.

O modelo proposto pelos autores foi capaz de classificar as amostras com uma acurácia de 76,1%, valor menor do que o encontrado neste trabalho quando avaliado a utilização de imagens de amostras não maturadas para classificar amostras no mesmo tempo de maturação: 90,9% de acurácia utilizando todos os comprimentos de onda e 84,1% quando selecionados os comprimentos de onda de maior interesse.

Cluff *et al.* (2013), utilizando um sistema HSI de varredura ($\lambda = 922\text{--}1739\text{ nm}$) adquiriram imagens com 243 bandas do músculo *Longissimus dorsi* de carcaças classificadas como *USDA choice* ou *select*. Os valores de referência da maciez foram obtidos usando a técnica SSF, em que as amostras foram divididas em duas classes: $\text{SSF} \geq 206\text{ N}$ consideradas duras e $\text{SSF} < 206\text{ N}$ consideradas macias. Aplicando o modelo LDA, os autores obtiveram uma acurácia de 83,3% e 75,0% na classificação das amostras, maturadas por 14 dias, em macias e duras, respectivamente. Os valores de acurácia apresentados pelo autor são superiores aos encontrados neste trabalho quando comparado ao mesmo tempo de maturação (14 dias) 73,9% e 76,2% para classificação das amostras macias e duras, respectivamente. No entanto, quando comparados

com outros tempos de maturação avaliados neste trabalho, valores de acurácia superiores foram encontrados, sendo 91,7% na identificação das amostras macias no tempo zero de maturação (utilizando imagens de amostras não maturadas) e 100% na identificação das amostras duras no tempo 14 classificando o tempo 21 de maturação.

5.3 Performance dos modelos de classificação dos tempos de maturação

Considerando as amostras em sua totalidade, a implementação do modelo LDA utilizando todos os comprimentos de onda (espectro completo), absorvância como transformação de espectro e efetuado os pré-tratamentos, obteve-se a classificação correta de 319 (1ª derivada) e 318 (2ª derivada) amostras do total de 376 amostras (Tabela 8 e Tabela 9), resultando em uma acurácia geral de 84,8% e 84,6% (Tabela 10), respectivamente. Para a avaliação do modelo um incremento menor que 2% nos valores de acurácia foi considerado não significativo.

Tabela 8. Classificação dos tempos de maturação do modelo linear discriminante para a transformada de absorvância com a 1ª derivada.

		Predito				
	Dias	0	7	14	21	Total
Atual	0	88	4	0	0	92
	7	6	80	9	1	96
	14	0	16	67	11	94
	21	0	0	10	84	94
	Total	94	100	86	96	376

Fonte: Própria autoria.

Tabela 9. Classificação dos tempos de maturação do modelo linear discriminante para a transformada de absorbância com a 2ª derivada.

		Predito				
		0	7	14	21	Total
Atual	Dias					
	0	89	3	0	0	92
	7	5	82	9	0	96
	14	0	13	67	14	94
	21	0	0	14	80	94
Total		94	98	90	94	376

Fonte: Própria autoria.

Tabela 10. Acurácia geral da classificação dos tempos de maturação.

		N F ¹	Comprimentos de onda (nm)	Maturação
Espectro Completo	Reflectância	7	928-2524	72,3
	Reflectância+1Derivada	7	928-2524	77,9
	Reflectância+2Derivada	7	928-2524	77,4
	Absorbância	7	928-2524	72,6
	Absorbância+1Derivada	7	928-2524	84,8
	Absorbância+2Derivada	7	928-2524	84,6
Espectro Parcial	Reflectância	6	928-1413	67,6
	Reflectância+1Derivada	7	928-1080;1212-1268	62,5
	Reflectância+2Derivada	7	941-973;985-1036;1136-1224	62,2
	Absorbância	7	928-2524	72,6
	Absorbância+1Derivada	7	1080-1212;1268-1463;1639-1733;1845-1939	80,0
	Absorbância+2Derivada	7	1105-1143;1224-1388;1739-1758;1839-1883	79,0

¹N F = Número de Fatores. Fonte: Própria autoria.

De acordo com Bratcher *et al.* (2005), para a carne bovina ser classificada como *USDA Select*, ela deve ser maturada por pelo menos 14 dias, bem como para que a carne bovina seja classificada como *USDA choice*, a mesma deve ser maturada por 7 dias. Sendo assim, para órgãos reguladores da qualidade, o sistema de imagem hiperespectral pode ser uma ferramenta para controle dos produtos, devido sua boa acurácia na classificação da carne bovina quanto ao tempo de maturação.

5.4 Performance dos modelos de classificação do pH

Utilizando o modelo LDA para classificação do pH em duas classes (normal e DFD), 73 amostras de um total de 78 amostras foram classificadas corretamente (Tabela 11), resultando numa acurácia geral de 93,6% (Tabela 12) ao utilizar todos os comprimentos de onda (espectro completo) associado às transformadas de espectro reflectância e absorbância com o pré-tratamento 2^a derivada.

Tabela 11. Classificação dos valores de pH usando o modelo linear discriminante com as transformadas de reflectância e absorbância com a 2^a derivada.

		Predito		
		Normal	DFD	Total
Atual	Normal	63	4	67
	DFD	1	10	11
	Total	64	14	78

Fonte: Própria autoria.

Tabela 12. Acurácia geral da classificação do pH.

		¹ N F	Comprimentos de onda (nm)	pH
Espectro Completo	Reflectância	7	928-2524	74,4
	Reflectância+1Derivada	7	928-2524	84,6
	Reflectância+2Derivada	7	928-2524	93,6
	Absorbância	7	928-2524	69,2
	Absorbância+1Derivada	7	928-2524	87,2
	Absorbância+2Derivada	7	928-2524	93,6
Espectro Parcial	Reflectância	7	928-1413	73,1
	Reflectância+1Derivada	7	928-1080;1212-1268	62,8
	Reflectância+2Derivada	7	941-973;985-1036;1136-1224	73,1
	Absorbância	7	928-2524	69,2
	Absorbância+1Derivada	7	1080-1212;1268-1463;1639-1733;1845-1939	79,5
	Absorbância+2Derivada	7	1105-1143;1224-1388;1739-1758;1839-1883	80,8

¹N F = Número de Fatores. Fonte: Própria autoria.

Diversos trabalhos relatam a eficácia da técnica de imagem hiperespectral para a predição dos valores de pH em amostras de carne bovina (ELMASRY; SUN; ALLEN, 2012) e suína (BARBIN; VALOUS; SUN, 2013; BARBIN *et al.*, 2012; QIAO *et al.*, 2007b; KAMRUZZAMAN *et al.*, 2012). Porém, pouco se encontra na literatura sobre a utilização desta técnica para a classificação de amostras quanto ao pH.

No entanto, em trabalho publicado por Qiao *et al.* (2007b), os autores classificaram amostras de carne suína em RFN (vermelha, firme e não exudativa), PFN (pálida, firme e não exudativa), PSE (pálida, mole e exudativa) e RSE (vermelha, mole e exudativa). Os autores utilizaram 40 amostras de lombo suíno e uma rede neural *feed-forward* como modelo de classificação, na qual

27 amostras foram utilizadas para treinamento da rede e 13 amostras foram usadas para teste. Em sua configuração de melhor desempenho, o autor obteve 85% de acurácia ao utilizar 10 componentes principais como entrada da rede.

O resultado encontrado pelos autores (QIAO *et al.*, 2007b) foi inferior ao resultado de acurácia geral encontrado neste trabalho (93,6%), ao utilizar todos os comprimentos de onda (espectro completo) associado às transformadas de espectro reflectância e absorbância com o pré-tratamento 2a derivada para classificar as amostras em Normal ($\text{pH} < 6$) e DFD ($\text{pH} \geq 6$).

6. Conclusões

A utilização da imagem hiperespectral como ferramenta para classificação dos atributos qualitativos da carne de bovinos Nelore: pH, maciez e tempos de maturação; pode ser considerada uma técnica robusta que fornece bons resultados, além de não exigir nenhum preparo especial das amostras e ser uma técnica não destrutiva.

7. Considerações Finais

As maiores vantagens da técnica de imagem hiperespectral é a rapidez e facilidade de aquisição das imagens. Porém, existem ainda diversos atributos qualitativos da carne, além de inúmeras utilizações do sistema de imagem hiperespectral, dentro dos estudos de qualidade da carne que podem ser explorados, como:

- Identificação de contaminantes,
- Identificação de resíduos na carne (promotores de crescimento e hormônios),
- Composição centesimal da carne,
- Quantificação e distribuição do marmoreio,
- Criação de mapas de predição.

8. Referências bibliográficas

- ABIEC, Associação das Indústrias Exportadoras de Carne. São Paulo, SP. **Estatísticas**, 2014. Disponível em: www.abiec.com.br Acesso em: 06 de Julho, 2015.
- ALOMAR, D. *et al.* Chemical and discriminant analysis of bovine meat by near infrared reflectance spectroscopy (NIRS). **Meat Science**, v.63, p.441–450, 2003.
- ALVES, D. D. *et al.* Maciez da carne bovina. **Ciência Animal Brasileira**, Goiânia, v. 6, n. 3, p. 135-149, 2005.
- American Meat Science Association - AMSA. Research guidelines for cookery, sensory evaluation and instrumental tenderness measurements of fresh meat. Savoy.1995.
- ASSOCIAÇÃO BRASILEIRA DE CRIADORES DE ZEBU. **Estatísticas**, 2015. Disponível em: <http://www.abcz.org.br/Home/Conteudo/22889-Estatisticas>. Acesso em: 06 de Julho 2016.
- AZEVEDO, P. R. A. O valor nutricional da carne. **Revista Nacional da Carne**, São Paulo, v.37, n.327, p.18-33, 2004.
- BARBIN, D. F. *et al.* Predicting quality and sensory attributes of pork using near-infrared hyperspectral imaging. **Analytica Chimica Acta**, v.719, p.30-42, 2012.
- BARBIN, D. F.; VALOUS, N. A.; SUN, D. – W. Tenderness prediction in porcine *longissimus dorsi* muscles using instrumental measurements along with

- NIR hyperspectral and computer vision imagery. **Innovative Food Science and Emerging Technologies**, v.20, p.335-342, 2013.
- BAULAIN-NEUSTADT, U. *et al.* Magnetic resonance tomography as a reference technique to determine body composition in pig performance testing. **Fleischwirtschaft**, v.84, p.101–104, 2004.
- BELK, K. E. *et al.* The use of video image analysis and instrumentation to predict beef palatability. **Proceeding Reciprocal Meat Conference**, v.53, p.10–15, 2000.
- BONIN, M. N. **Estudo da influência de touro e de genearca da raça Nelore nos aspectos quantitativos e qualitativos de carcaça e da carne.** Tese do Doutorado. Faculdade de Zootecnia e Engenharia de Alimentos da Universidade de São Paulo, 2008. (<http://www.teses.usp.br/5554028.pdf>).
- BRATCHER, C. L. *et al.* The effects of quality grade, aging, and location within muscle on Warner–Bratzler shear force in beef muscles of locomotion. **Meat Science**, v. 70, p. 279–284, 2005.
- BROOKS, S. L. Computed tomography. **Dental Clinics of North America**, Philadelphia, v.37, n.4, p.575-590, 1993.
- CHAO, K. *et al.* Chicken heart disease characterization by multi-spectral imaging. **Applied Engineering in Agriculture**, v.17, p.99–106, 2001.
- CHAU, A. *et al.* Innovative sensors to rapidly and non-destructively determine fish freshness. Seafish Industry Authority. **Report No. CMS/REP/110284/1**, 2009.

- CLUFF, K. *et al.* Optical scattering in beef steak to predict tenderness using hyperspectral imaging in the VIS-NIR region. **Sensing and Instrumentation for Food Quality and Safety**, v.2, p.189–196, 2008.
- CLUFF, K. *et al.* Optical scattering with hyperspectral imaging to classify longissimus dorsi muscle based on beef tenderness using multivariate modeling. **Meat Science**, v. 95, p. 42-50, 2013.
- COZZOLINO, D.; DE MATTOS, D.; VAZ MARTINS, D. Visible/near infrared reflectance spectroscopy for predicting composition and tracing system of production of beef muscle. **Animal Science**, v.74, p.477–484, 2002.
- DABÉS, A. C. Propriedades da carne fresca. **Revista Nacional da Carne**, São Paulo, v. 25, n. 288, p. 32-40, 2001.
- DALARI, M. Demandas do consumidor e como o varejo vê o mercado. In: **INTERNATIONAL MEAT CONFERENCE**, São Paulo, 2007.
- DAMEZ, J. L.; CLERJON, S. Meat quality assessment using biophysical methods related to meat structure. **Meat Science**, v. 80, p. 132–149, 2008.
- DA-WEN SUN. **Hyperspectral Imaging for Food Quality Analysis and Control**. Academic Press/Elsevier, San Diego, California, USA, 2010. 447p.
- DELGADO C. *et al.* **Livestock to 2020 – The Next Food Revolution**. Food, Agriculture and the Environment Discussion Paper 28. IFPRI, Washington D.C. 1999.
- DRANSFIELD, E. Modeling post-mortem tenderization. III - Role of calpain I in conditioning. **Meat Scienc**, v. 31, p. 85-94, 1992.

- DRANSFIELD, E. Modeling post-mortem tenderization. IV - Role of calpain and calpastatin in conditioning. **Meat Science**, v. 34, p. 217-234, 1993.
- ELMASRY, G. *et al.* Early detection of apple bruises on different background colors using hyperspectral imaging. **LWT-Food Science and Technology**, v. 41, p. 337–345, 2008.
- ELMASRY, G.; SUN, D.-W. Meat quality assessment using a hyperspectral imaging system. In: SUN, DA-WEN (Ed.), **Hyperspectral Imaging for Food Quality Analysis and Control**. Academic Press/Elsevier, San Diego, California, USA, p. 273–294, 2010.
- ELMASRY, G.; SUN, D-W.; ALLEN, P. Near-infrared hyperspectral imaging for predicting colour, pH and tenderness of fresh beef. **Journal of Food Engineering**, v. 110, p. 127-140, 2012.
- ELMASRY, G.; WOLD, J. P. High-speed assessment of fat and water content distribution in Fish fillets using online imaging spectroscopy. **Journal of Agricultural and Food Chemistry**, v. 56, n. 17, p. 7672–7677, 2008.
- EUCLIDES FILHO, K.; SILVA, L.O.C.; ALVES, R.G.O. *et al.* Tendência genética na raça gir. **Pesquisa Agropecuária Brasileira**, v.35, p.787-791, 2000.
- FELÍCIO, PE de. Avaliação da qualidade da carne bovina. In: **Simpósio sobre Produção Intensiva de Gado de Corte**, p. 92-99, 1998.
- FRANDSON, R. D. **Anatomia e fisiologia dos animais domésticos**. Rio de Janeiro: Guanabara, 1979. 429p.
- GARRIDO, M.D.; BAÑÓN, S.; ÁLVAREZ, D. Medida del pH. Estandarización de las metodologías para evaluar la calidad del producto (animal vivo, canal, carne y grasa) en los rumiantes. In: Cañeque, V.; Sañudo, C. (ed),

Estandarización de las metodologías para evaluar la calidad del producto (animal vivo, canal, carne y grasa) en los rumiantes.

Monografías INIA: Série Ganadera, p. 206-215, 2005.

GREASER, M. L.; GUO, W. **Handbook of Meat and Meat Processing**. Second Edition. CRC Press, p. 63-78, 2012.

HADLICH, J. C. *et al.* Efeito do colágeno na maciez da carne de bovinos de distintos grupos genéticos. **Acta Science and Animal Science Maringá**, v. 28, n. 1, p. 57–62, 2006.

HERRERO, A. N. Raman spectroscopy a promising technique for quality assessment of meat and fish: a review. **Food Chemistry**, v.107, p.1642–1651, 2008.

HOCQUETTE, J.F. *et al.* Nutritional and hormonal regulation of energy metabolism in skeletal muscles of meat-producing animals. **Livestock Production Science**, v. 56, p. 115-143, 1998.

HOLLUNG, K. *et al.* Application of proteomics to understand the molecular mechanisms behind meat quality. **Meat Science**, v. 77, p. 97-104, 2007.

HOLLUNG, K.; VEISETH-KENT, E. **Omics Techonologies: Tools for food science**. Nouredine Benkeblia, *University of the West Indies, Kingston, Jamaica*. CRC Press, p. 313-338, 2012.

HOPKINS, D.L. *et al.* Video image analysis in in the Australian meat industry – precision and accuracy of predicting lean meat yield in lamb carcasses. **Meat Science**, v. 67, p. 269–274, 2004.

- KAMRUZZAMAN, M. *et al.* Application of NIR hyperspectral imaging for discrimination of lamb muscles. **Journal of Food Engineering**, v. 104, p. 332-340, 2011.
- KAMRUZZAMAN, M. *et al.* Prediction of some quality attributes of lamb meat using near-infrared hyperspectral imaging and multivariate analysis. **Analytica Chimica Acta**, v. 714, p. 57– 67, 2012.
- KEMP, C. M. *et al.* Tenderness – Na enzymatic view. **Meat Science**, v. 84, p. 248 – 256, 2010.
- KESKIN, M. *et al.* Assessing nitrogen content of golf course turfgrass clippings using spectral reflectance. **Applied Engineering in Agriculture**, v. 20 n. 6, p. 851–860, 2004.
- KIM, I. *et al.* Detection of skin tumors on chicken carcasses using hyperspectral fluorescence imaging. **Transactions of the ASAE**, v. 47, n. 5, p. 1785–1792, 2004.
- KLAYPRADIT, W.; KERDPIBOON, S.; SINGH, R. K. Application of artificial neural networks to predict the oxidation of menhaden fish oil obtained from Fourier transform infrared spectroscopy method. **Food and Bioprocess Technology**, v. 4, n. 3, p. 475-480, 2011.
- KONDA NAGANATHAN, G. *et al.* Hyperspectral imaging of ribeye muscle on hanging beef carcasses for tenderness assessment. **Computers and Electronics in Agriculture**, v. 116, p. 55–64, 2015.
- KONDA NAGANATHAN, G. *et al.* Partial least squares analysis of near-infrared hyperspectral images for beef tenderness prediction. **Sensing and Instrumentation Food Quality**, v. 2, p. 178–188, 2008b.

- KONDA NAGANATHAN, G. *et al.* Three dimensional chemometric analyses of hyperspectral images for beef tenderness forecasting. **Journal of Food Engineering**, v. 169, p. 309–320, 2016.
- KONDA NAGANATHAN, G. *et al.* Visible/near-infrared hyperspectral imaging for beef tenderness prediction. **Computers and Electronics in Agriculture**, v. 64, p. 225–233, 2008a.
- KONG, S.G. *et al.* Analysis of hyperspectral fluorescence images for poultry skin tumour inspection. **Applied Optics**, v. 43, n. 4, p. 824–833, 2004.
- KOOHMARAIE, M. *et al.* Acceleration of *post mortem* tenderization in lamb and Brahman-cross beef carcasses through infusion of calcium chloride. **Journal of Animal Science**, v. 68, n. 5, p. 1278-1283, 1990.
- KOOHMARAIE, M. The biological basis of meat tenderness and potential genetic approaches for its control and prediction. **Proceedings of the Reciprocal Meat Conference**, v. 48, p. 69–75, 1995.
- KOOHMARAIE, M.; GESSINK, G. H. Contribution of postmortem muscle biochemistry to the delivery of consistent meat quality with particular focus on the calpain system. **Meat Science**, v. 74, p. 34-43, 2006.
- KORKEALA, H. *et al.* Determination of pH in meat. **Meat Science**, v. 18, n. 2, p. 121-132, 1986.
- KUMAR, S.; MITTAL, G. S. Rapid detection of microorganisms using image processing parameters and neural network. **Food and Bioprocess Technology**, v. 3, n. 5, p. 741-751, 2009.
- LAWRIE, R. A. **Ciência da Carne**. 6 ed. Porto Alegre: Artmed. 2005.

- LIMA, F.P. **Nelore: a força de uma raça**. São Paulo: Associação de criadores de Nelore do Brasil, 1989. 129p.
- LIU, Y. *et al.* Improvement of near-infrared spectral calibration models for brix prediction in 'Gannan' navel oranges by a portable near-infrared device. **Food and Bioprocess Technology**, v. 3, n. 4, p. 561-567, 2010.
- McGEEHIN; SHERDAN, J. J.; BUTLER, F. Factors affecting the pH decline in lamb after slaughter. **Meat Science**, n. 58, p. 79-84, 2001.
- MENESATTI, P. *et al.* Supervised multivariate analysis of hyper-spectral NIR images to evaluate the starch index of apples. **Food and Bioprocess Technology**, v. 2, p. 308–314, 2009.
- MILLER, R. K. Obtendo carne de qualidade consistente. In: CONGRESSO BRASILEIRO DE CIÊNCIA E TECNOLOGIA DE CARNES, 1., 2001, São Pedro. *Anais...* São Pedro, 2001. p.123-142.
- MONIN, G. Stress d'abattage et qualities de la viande. **Recherches Médecine Veterinérie**, v. 164, n. 10, p.835-842, 1988.
- NAKARIYAKUL, S.; CASASENT, D. Hyperspectral waveband selection for contaminant detection on poultry carcasses. **Optical Engineering**, v. 47, n. 8, p. 087202–087209, 2008.
- NAVAJAS, E. A. *et al.* Accuracy of in vivo muscularity indices measured by computed tomography and their association with carcass quality in lambs. **Meat Science**, v. 75, p. 533-542, 2007.
- OLIVEIRA, J.H.F.; MAGNABOSCO, C.U.; BORGES, A.M.S.M. **Nelore: basegenética e evolução seletiva no Brasil**. Planaltina: Embrapa Cerrados, 2002. 54p.

- OSÓRIO, J.C.S; OSÓRIO, M.T.M.; SAÑUDO, C. Características sensoriais da carne ovina. **Revista Brasileira de Zootecnia**, v. 38, p. 292-300, 2009. (Suplemento Especial).
- PALLOTTINO, F. *et al.* Image analysis techniques for automated hazelnut peeling determination. **Food and Bioprocess Technology**, v. 3, n. 1, p. 155–159, 2010.
- PAPAIZ, E. G.; CARVALHO, P. L. Métodos recentes de diagnóstico através da imagem. **Radiologia odontológica**. São Paulo: Artes Médicas, 4 ed., cap. 34, p. 667-684, 1998.
- PARK, B. *et al.* Contaminant classification of poultry hyperspectral imagery using a spectral angle mapper algorithm. **Biosystems Engineering**, v. 96, n. 3, p. 323–333, 2007.
- PARKS, E. T. Computed tomography applications for dentistry. **Dent Clin North Am**, Philadelphia, v. 44, n. 2, p. 371-394, 2000.
- QIAO, J. *et al.* Pork quality and marbling level assessment using a hyperspectral imaging system. **Journal of Food Engineering**, v. 83, p. 10–16, 2007a.
- QIAO, J. *et al.* Pork quality classification using a hyperspectral imaging system and neural network. **International Journal of Food Engineering**, v. 3 n. 1, p. 6, 2007b.
- QIAO, J. *et al.* Prediction of drip-loss, pH & color for pork using a hyperspectral imaging technique. **Meat Science**, v. 76, p. 1–8, 2007c.
- QUEVEDO, R. A.; AGUILERA, J. M.; PEDRESCHI, F. Color of salmon fillets by computer vision and sensory panel. **Food and Bioprocess Technology**, v. 3, n. 5, p. 637-643, 2010.

- QUEVEDO, R.; AGUILERA, J. M. Computer vision and stereoscopy for estimating firmness in the salmon (Salmon salar) fillets. **Food and Bioprocess Technology**, v. 3, n. 4, 2010.
- ROÇA, R. O. **Modificações pós-morte da carne**. Disponível em: <<http://pucrs.campus2.br/~thompson/Roca105.pdf>> Acesso em: 12 de Junho, 2013.
- SAINZ, R. D.; ARAÚJO, F. R. C. Tipificação de carcaças de bovinos e suínos. In: CONGRESSO BRASILEIRO DE CIÊNCIA E TECNOLOGIA DE CARNES, São Pedro. **Anais...** São Pedro, p. 26-55, 2001.
- SANTIAGO, A.A. O Nelore: origem, formação e evolução do rebanho. São Paulo: Editora dos Criadores, p. 27-28, 1983.
- SAÑUDO, C. *et al.* Small ruminant production systems and factors affecting lamb meat quality. **Meat Science**, v. 49, n. 1, p. 29-64, 1998.
- SAWDY, J. C. *et al.* Myofibrillar 1-D fingerprints and myosin heavy chain MS analyses of beef loin at 36 h postmortem correlate with tenderness at 7 days. **Meat Science**, v. 67, p. 421–426, 2004.
- SCHENKEL, F.S.; LAGIOIA, D.R.; RIBOLDI, J. Níveis de endogamia e depressão endogâmica no ganho de peso de raças zebuínas no Brasil. In: **Sociedade Brasileira de Melhoramento Animal**, IV Simpósio Nacional de Melhoramento Animal, Campo Grande, Anais... Campo Grande: SBMA, 2002.
- SEPÚLVEDA, W. S.; MAZA, M. T.; PARDOS, L. Aspects of quality related to the consumption and production of lamb meat consumers versus producers. **Meat Science**, v. 87, p. 366–372, 2011.

- SHACKELFORD S. D. et al. Heritabilities and phenotypic and genetic correlations for bovine postrigor calpastatin activity, intramuscular fat content, Warner-Bratzler shear force, retail product yield, and growth rate. **Journal of Animal Science**, v. 72, p. 857-863, 1993.
- SIVERTSEN, A. H. *et al.* Ridge detection with application to automatic fish fillet inspection. **Journal of Food Engineering**, v. 90, p. 317–324, 2009.
- TROY, D. J.; KERRY, J. P. Consumer perception and the role of science in the meat industry. **Meat Science**, v. 86, p. 214–226, 2010.
- VARELLA, C. A. A. **Análise multivariada aplicada a ciências agrárias**. Universidade Federal Rural do Rio de Janeiro, 2016. Disponível em: <http://www.ufrjr.br/institutos/it/deng/varella/Downloads/multivariada%20aplicada%20as%20ciencias%20agrarias/Aulas/ANALISE%20DISCRIMINANTE.pdf> Acesso em: 10 de abril de 2016.
- VEISETH, E.; KOOHMARAIE, M. Effect of extraction buffer on estimating calpain and calpastatin activity in *post mortem* ovine muscle. **Meat Science**, v. 57, n. 3, p. 325-329, 2001.
- VOTE, D. J. *et al.* Online prediction of beef tenderness using a computer vision system equipped with a BeefCam module. **Journal of Animal Science**, v. 81, p. 457–465, 2003.
- WATANABE, A.; DALY, C. C.; DEVINE, C. E. The effects of the ultimate pH of meat on tenderness changes during ageing. **Meat Science**, v. 42, n. 1, p. 67-78, 1996.

WOLD, J. P. *et al.* Non-contact transfectance near infrared imaging for representative on-line sampling of dried salted coalfish (bacalao). **Journal of Near Infrared Spectroscopy**, v. 14, n. 1, p. 59–66, 2006.

XUE, J.; TITTERINGTON, D. M. Do unbalanced data have a negative effect on LDA? **Pattern Recognition**, v. 41, n. 5, p. 1558–1571, 2008.

9. APÊNDICES

Apêndice 1- Matrizes de Confusão para o Espectro Parcial (Maciez)

Tabela 1.1. Matriz de confusão para o espectro 0 – WBSF 0.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	10	2	12	64
Reflectância+1Derivada	11	1	19	57
Reflectância+2Derivada	11	1	15	61
Absorbância	10	2	8	68
Absorbância+1Derivada	10	2	7	69
Absorbância+2Derivada	10	2	8	68

Fonte: Própria autoria.

Tabela 1.2. Matriz de confusão para o espectro 0 e WBSF 7.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	23	13	19	33
Reflectância+1Derivada	23	13	19	33
Reflectância+2Derivada	24	12	19	33
Absorbância	23	13	19	33
Absorbância+1Derivada	23	13	19	33
Absorbância+2Derivada	23	13	19	33

Fonte: Própria autoria.

Tabela 1.3. Matriz de confusão para o espectro 0 e WBSF 14.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	40	27	6	15
Reflectância+1Derivada	38	29	6	15
Reflectância+2Derivada	49	18	4	17
Absorbância	40	27	6	15
Absorbância+1Derivada	51	16	7	14
Absorbância+2Derivada	56	11	8	13

Fonte: Própria autoria.

Tabela 1.4. Matriz de confusão para o espectro 0 e WBSF 21.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	57	20	1	10
Reflectância+1Derivada	59	18	3	8
Reflectância+2Derivada	49	28	3	8
Absorbância	56	21	2	9
Absorbância+1Derivada	48	29	3	8
Absorbância+2Derivada	46	31	3	8

Fonte: Própria autoria.

Tabela 1.5. Matriz de confusão para o espectro 7 e WBSF 7.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	26	12	14	38
Reflectância+1Derivada	25	13	18	34
Reflectância+2Derivada	27	11	18	34
Absorbância	26	12	13	39
Absorbância+1Derivada	25	13	19	33
Absorbância+2Derivada	25	13	18	34

Fonte: Própria autoria.

Tabela 1.6. Matriz de confusão para o espectro 7 e WBSF 14.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	40	28	6	16
Reflectância+1Derivada	39	29	6	16
Reflectância+2Derivada	40	28	6	16
Absorbância	41	27	10	12
Absorbância+1Derivada	44	24	7	15
Absorbância+2Derivada	39	29	6	16

Fonte: Própria autoria.

Tabela 1.7. Matriz de confusão para o espectro 7 e WBSF 21.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	59	18	3	10
Reflectância+1Derivada	55	22	3	10
Reflectância+2Derivada	43	34	4	9
Absorbância	55	22	2	11
Absorbância+1Derivada	60	17	2	11
Absorbância+2Derivada	45	32	4	9

Fonte: Própria autoria.

Tabela 1.8. Matriz de confusão para o espectro 14 e WBSF 14.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	44	23	7	14
Reflectância+1Derivada	44	23	7	14
Reflectância+2Derivada	40	29	6	15
Absorbância	46	23	6	15
Absorbância+1Derivada	39	30	6	15
Absorbância+2Derivada	42	27	7	14

Fonte: Própria autoria.

Tabela 1.9. Matriz de confusão para o espectro 14 e WBSF 21.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	60	14	0	14
Reflectância+1Derivada	51	23	2	12
Reflectância+2Derivada	57	18	3	12
Absorbância	58	17	3	12
Absorbância+1Derivada	63	12	2	13
Absorbância+2Derivada	63	12	2	13

Fonte: Própria autoria.

Tabela 1.10. Matriz de confusão para o espectro 21 e WBSF 21.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	55	11	3	10
Reflectância+1Derivada	48	18	2	11
Reflectância+2Derivada	48	18	2	11
Absorbância	57	9	2	11
Absorbância+1Derivada	55	11	3	10
Absorbância+2Derivada	58	8	1	12

Fonte: Própria autoria.

Apêndice 2 - Matrizes de Confusão para o Espectro Completo (Maciez)

Tabela 2.1. Matriz de confusão para o espectro 0 e WBSF 0.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	10	2	6	70
Reflectância+1Derivada	10	2	8	68
Reflectância+2Derivada	10	2	16	60
Absorbância	10	2	7	69
Absorbância+1Derivada	10	2	7	69
Absorbância+2Derivada	10	2	10	66

Fonte: Própria autoria.

Tabela 2.2. Matriz de confusão para o espectro 0 e WBSF 7.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	22	14	22	30
Reflectância+1Derivada	23	13	22	30
Reflectância+2Derivada	22	14	25	27
Absorbância	23	13	20	32
Absorbância+1Derivada	19	17	21	31
Absorbância+2Derivada	22	14	20	32

Fonte: Própria autoria.

Tabela 2.3. Matriz de confusão para o espectro 0 e WBSF 14.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	50	17	9	12
Reflectância+1Derivada	48	19	9	12
Reflectância+2Derivada	44	23	6	15
Absorbância	47	20	6	15
Absorbância+1Derivada	38	29	9	12
Absorbância+2Derivada	41	26	7	14

Fonte: Própria autoria.

Tabela 2.4. Matriz de confusão para o espectro 0 e WBSF 21.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	57	19	2	10
Reflectância+1Derivada	47	29	2	10
Reflectância+2Derivada	48	28	4	8
Absorbância	52	24	3	9
Absorbância+1Derivada	49	27	4	8
Absorbância+2Derivada	55	21	4	8

Fonte: Própria autoria.

Tabela 2.5. Matriz de confusão para o espectro 7 e WBSF 7.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	26	14	21	31
Reflectância+1Derivada	28	12	18	34
Reflectância+2Derivada	24	16	21	31
Absorbância	24	16	17	35
Absorbância+1Derivada	26	14	16	36
Absorbância+2Derivada	26	14	20	32

Fonte: Própria autoria.

Tabela 2.6. Matriz de confusão para o espectro 7 e WBSF 14.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	47	23	8	14
Reflectância+1Derivada	47	23	7	15
Reflectância+2Derivada	47	23	8	14
Absorbância	50	20	6	16
Absorbância+1Derivada	51	19	7	15
Absorbância+2Derivada	46	24	7	15

Fonte: Própria autoria.

Tabela 2.7. Matriz de confusão para o espectro 7 e WBSF 21.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	61	18	2	11
Reflectância+1Derivada	56	23	2	11
Reflectância+2Derivada	51	28	4	9
Absorbância	60	19	2	11
Absorbância+1Derivada	59	20	2	11
Absorbância+2Derivada	58	21	2	11

Fonte: Própria autoria.

Tabela 2.8. Matriz de confusão para o espectro 14 e WBSF 14.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	45	24	11	10
Reflectância+1Derivada	46	23	8	13
Reflectância+2Derivada	46	23	7	14
Absorbância	51	18	10	11
Absorbância+1Derivada	43	26	7	14
Absorbância+2Derivada	48	21	5	16

Fonte: Própria autoria.

Tabela 2.9. Matriz de confusão para o espectro 14 e WBSF 21.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	65	12	1	12
Reflectância+1Derivada	61	16	1	12
Reflectância+2Derivada	61	16	3	10
Absorbância	61	16	3	10
Absorbância+1Derivada	58	19	1	12
Absorbância+2Derivada	54	23	3	10

Fonte: Própria autoria.

Tabela 2.10. Matriz de confusão para o espectro 21 e WBSF 21.

	Macia atual – Macia predito	Macia atual – Dura predito	Dura atual – Macia predito	Dura atual – Dura predito
Reflectância	61	16	2	11
Reflectância+1Derivada	48	29	4	9
Reflectância+2Derivada	55	22	4	9
Absorbância	61	16	1	12
Absorbância+1Derivada	62	15	2	11
Absorbância+2Derivada	65	12	1	12

Fonte: Própria autoria.

Apêndice 3 - Matrizes de Confusão para o Espectro Completo (Tempos de Maturação)

Tabela 3.1. Matriz de confusão para os tempos de maturação.

	A 0	A 0	A 0	A 0	A 7	A 7	A 7	A 7	A 14	A 14	A 14	A 14	A 21	A 21	A 21	A 21
	P 0	P 7	P 14	P 21	P 0	P 7	P 14	P 21	P 0	P 7	P 14	P 21	P 0	P 7	P 14	P 21
Reflectância	84	8	0	0	8	74	12	2	0	17	49	28	0	6	23	65
Reflectância+1Derivada	89	3	0	0	4	75	17	0	0	17	60	17	0	2	23	69
Reflectância+2Derivada	83	9	0	0	8	72	13	3	0	18	61	15	0	3	16	75
Absorbância	84	8	0	0	7	75	11	3	0	17	50	27	0	7	23	64
Absorbância+1Derivada	88	4	0	0	6	80	9	1	0	16	67	11	0	0	10	84
Absorbância+2Derivada	89	3	0	0	5	82	9	0	0	13	67	14	0	0	14	80

*A = Atual; P = Predito

Fonte: Própria autoria.

Apêndice 4 - Matrizes de Confusão para o Espectro Parcial (Tempos de Maturação)

Tabela 4.1. Matriz de confusão para os tempos de maturação.

	A 0	A 0	A 0	A 0	A 7	A 7	A 7	A 7	A 14	A 14	A 14	A 14	A 21	A 21	A 21	A 21
	P 0	P 7	P 14	P 21	P 0	P 7	P 14	P 21	P 0	P 7	P 14	P 21	P 0	P 7	P 14	P 21
Reflectância	83	9	0	0	7	68	17	4	2	27	39	26	0	14	16	64
Reflectância+1Derivada	77	15	0	0	11	61	18	6	4	20	37	33	1	13	20	60
Reflectância+2Derivada	79	12	0	1	13	50	23	10	1	35	38	20	1	10	16	67
Absorbância	84	8	0	0	7	75	11	3	0	17	50	27	0	7	23	64
Absorbância+1Derivada	88	4	0	0	2	81	10	3	0	8	66	20	0	6	22	66
Absorbância+2Derivada	89	3	0	0	3	72	21	0	0	17	60	17	0	0	18	76

*A = Atual; P = Predito

Fonte: Própria autoria.

Apêndice 5 - Matrizes de Confusão para o Espectro Parcial (pH)

Tabela 5.1. Matriz de confusão para o pH.

	Atual Normal – Predito Normal	Atual Normal – Predito DFD	Atual DFD – Predito Normal	Atual DFD – Predito DFD
Reflectância	47	20	1	10
Reflectância+1Derivada	41	26	3	8
Reflectância+2Derivada	49	18	3	8
Absorbância	46	21	3	8
Absorbância+1Derivada	53	14	2	9
Absorbância+2Derivada	54	13	2	9

Fonte: Própria autoria.

Apêndice 6 - Matrizes de Confusão para o Espectro Completo (pH)

Tabela 6.1. Matriz de confusão para o pH.

	Atual Normal – Predito Normal	Atual Normal – Predito DFD	Atual DFD – Predito Normal	Atual DFD – Predito DFD
Reflectância	48	19	1	10
Reflectância+1Derivada	56	11	1	10
Reflectância+2Derivada	63	4	1	10
Absorbância	46	21	3	8
Absorbância+1Derivada	57	10	0	11
Absorbância+2Derivada	63	4	1	10

Fonte: Própria autoria.

Apêndice 7 – Gráficos para seleção de comprimento de onda para os tempos de maturação

Figura 15. Média dos espectros com base no tempo de maturação - Reflectância.

Fonte: Própria autoria.

Figura 16. Média dos espectros com base no tempo de maturação – Reflectância + 1ª Derivada.

Fonte: Própria autoria.

Figura 17. Média dos espectros com base no tempo de maturação – Reflectância + 2ª Derivada.

Fonte: Própria autoria.

Figura 18. Média dos espectros com base no tempo de maturação - Absorbância.

Fonte: Própria autoria.

Figura 19. Média dos espectros com base no tempo de maturação – Absorbância + 1ª Derivada.

Fonte: Própria autoria.

Figura 20. Média dos espectros com base no tempo de maturação – Absorbância + 2ª Derivada.

Fonte: Própria autoria.

Apêndice 8 – Gráficos para seleção de comprimento de onda para os valores de pH

Figura 21. Média dos espectros com base nos valores de pH – Reflectância.

Fonte: Própria autoria.

Figura 22. Média dos espectros com base nos valores de pH – Reflectância + 1ª Derivada.

Fonte: Própria autoria.

Figura 23. Média dos espectros com base nos valores de pH – Reflectância + 2ª Derivada.

Fonte: Própria autoria.

Figura 24. Média dos espectros com base nos valores de pH – Absorbância.

Fonte: Própria autoria.

Figura 25. Média dos espectros com base nos valores de pH – Absorbância + 1^a Derivada.

Fonte: Própria autoria.

Figura 26. Média dos espectros com base nos valores de pH – Absorbância + 2^a Derivada.

Fonte: Própria autoria.