

UNIVERSIDADE ESTADUAL DE MATO GROSSO DO SUL
UNIDADE UNIVERSITÁRIA DE AQUIDAUANA PROGRAMA
DE PÓS-GRADUAÇÃO EM ZOOTECNIA

APRENDIZADO DE MÁQUINA NA CLASSIFICAÇÃO E AVALIAÇÃO DE
DIFERENTES TIPOS DE FIBRAS MUSCULARES ATRAVÉS DA
ESPECTRORADIOMETRIA

Discente: Millena Vitória da Silva

Aquidauana/MS

Junho

2026

UNIVERSIDADE ESTADUAL DE MATO GROSSO DO SUL UNIDADE
UNIVERSITÁRIA DE AQUIDAUANA
PROGRAMA DE PÓS-GRADUAÇÃO EM ZOOTECNIA

APRENDIZADO DE MÁQUINA NA CLASSIFICAÇÃO E AVALIAÇÃO DE
DIFERENTES TIPOS DE FIBRAS MUSCULARES ATRAVÉS DA
ESPECTRORADIOMETRIA

Discente: Millena Vitória da Silva
Orientador: Prof. Dr. Dalton Mendes de Oliveira

“Dissertação apresentada ao Programa de Pós-graduação em Zootecnia, área de concentração em Produção Animal no Cerrado-Pantanal, da Universidade Estadual de Mato Grosso do Sul, como parte das exigências para a obtenção do título de Mestre em Zootecnia.”

Aquidauana/ MS

Junho
2026

S581

Silva, Millena Vitória da

Aprendizado de máquina na classificação e avaliação de diferentes tipos de fibras musculares através da espectrorradiometria / Millena Vitória da Silva. – Aquidauana MS: UEMS, 2026.

95 p.

Dissertação (Mestrado) – Zootecnia – Universidade Estadual de Mato Grosso do Sul, 2026.

Orientadora: Profa. Dra. Dalton Mendes de Oliveira

1. Aprendizado de máquina. 2. Fibras musculares. 3. Espectrorradiometria. 4. Métodos não destrutivos. 5. Qualidade da carne. I. Oliveira, Dalton Mendes. II. Título.

CDD 23. ed. - 664.9


**UNIVERSIDADE ESTADUAL DE MATO GROSSO DO
SUL PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E
INOVAÇÃO**

**UNIDADE UNIVERSITÁRIA DE AQUIDAUANA
PROGRAMA DE PÓS-GRADUAÇÃO EM
ZOOTECNIA ÁREA DE CONCENTRAÇÃO EM
PRODUÇÃO ANIMAL**

MILLENA VITÓRIA DA SILVA

Dissertação submetida ao Programa de Pós-Graduação em Zootecnia, área de concentração em Produção Animal, como requisito para obtenção do grau de Mestra em Zootecnia.

DISSERTAÇÃO APROVADA EM 10/06/2026.



Dr. Dalton Mendes de Oliveira (Orientador)

Dr. Adriano Carvalho Costa, IF-GOIANO
(participação via videoconferência)

Dra. Dthenifer Cordeiro Santana, UEMS
(participação via videoconferência)

Dedico esta dissertação, primeiramente, a Deus, que foi meu alicerce e minha força em todos os momentos, sem o qual nada disso teria sido possível. Ao meu esposo e aos meus pais, pelo amor, incentivo e apoio incondicional, que foram fundamentais em cada etapa dessa caminhada. Ao meu orientador, Dalton Mendes de Oliveira, pela orientação atenciosa, paciência e apoio ao longo de todo o desenvolvimento deste trabalho.

.

AGRADECIMENTOS

Primeiramente, agradeço a Deus, por ter me concedido saúde, força e sabedoria para concluir esta importante etapa da minha vida. Sem Sua presença constante, nada disso teria sido possível.

Ao meu esposo, por caminhar ao meu lado em todos os momentos, pelo apoio incondicional, pela paciência e pelo incentivo diário para que eu nunca desistisse, mesmo nos dias mais difíceis. Aos meus pais, que sempre acreditaram em mim e jamais mediram esforços para me apoiar, incentivar e impulsionar a ir cada vez mais longe. Todo meu amor e gratidão a vocês.

Aos meus queridos amigos, que me acompanham desde a graduação e permaneceram ao meu lado durante o mestrado, agradeço por tornarem essa jornada mais leve e especial. Cada encontro, cada conversa e cada momento de descontração foram fundamentais, não apenas para o crescimento profissional, mas também pessoal. Em especial, às minhas companheiras de sala, laboratório e projetos — Kelly, Dani e Carol — minha gratidão por toda ajuda, parceria e amizade. Obrigada por compartilharem os desafios, os “perrengues” e as risadas comigo; sem vocês, essa caminhada teria sido muito mais difícil. Chegamos ao fim de um ciclo marcado por aprendizados, lágrimas e muitas conquistas.

Agradeço, de forma muito especial, ao Aldair, por estar presente desde o início da graduação até este momento. Obrigada por todos os ensinamentos, ideias, incentivos e, principalmente, por sempre acreditar que eu era capaz de ir além. Sou imensamente grata pela dedicação, pela prontidão em ajudar e pela amizade construída ao longo dessa trajetória. Que Deus, em Sua infinita bondade, continue abençoando sua vida e permitindo que você transmita todo o seu conhecimento a muitas pessoas, pelo excelente profissional que é.

Agradeço ao meu orientador, Prof. Dr. Dalton Mendes de Oliveira, meu primeiro e único orientador desde a graduação até aqui. Um profissional humano, paciente e dedicado, que nunca mediu esforços para ensinar, orientar e apoiar. Obrigada por acreditar no meu potencial, pela paciência, pelo apoio em cada projeto e por nunca desistir de mim, mesmo quando eu mesma duvidava. Todas as conquistas que alcancei no meio acadêmico devo, primeiramente, a Deus e ao senhor, por investir e confiar no meu potencial. Que o meio acadêmico possa contar com mais orientadores como o senhor.

Ao grupo de estudos em Avaliação de carcaça e qualidade de carnes (GEQUAC).

Ao programa de Pós-Graduação em Zootecnia da Universidade Estadual de Mato

Grosso do Sul.

À Coordenação de aperfeiçoamento profissional de nível superior (CAPES) pela concessão da bolsa de estudos;

A todos os professores que fizeram parte desta minha jornada, o meu agradecimento por todos os ensinamentos repassados.

SUMÁRIO

CAPÍTULO 1 – CONSIDERAÇÕES GERAIS	12
1. INTRODUÇÃO	12
2. REVISÃO DE LITERATURA	15
2.1 Parâmetros qualitativos das fibras musculares avaliadas	15
2.2 Avaliação qualitativa da carne: abordagens convencionais e das inovações em aprendizado de máquina	21
2.3 Sensores hiperespectrais	25
3. OBJETIVOS	27
3.1 Objetivo Geral	27
3.2 Objetivos Específicos	28
REFERÊNCIAS BIBLIOGRÁFICAS	29
CAPÍTULO 2 - Avaliação espectral e aprendizado de máquina na predição de parâmetros físico-químicos da carne bovina	36
1. INTRODUÇÃO	38
2. MATERIAL E MÉTODOS	40
2.1 Local e procedimentos	40
2.2 Análises quantitativas e qualitativas	40
2.3 Análise espectral	43
2.4 Aprendizado de máquina	43
2.5 Análise estatística	44
3. RESULTADOS	46
4. DISCUSSÃO	48
5. CONCLUSÃO	52
REFERÊNCIAS	53
CAPÍTULO 3 – Predição de atributos qualitativos da carne de frango e suíno a partir de dados espectrais utilizando aprendizado de máquina	61
RESUMO	62
1. INTRODUÇÃO	63
2. MATERIAL E MÉTODOS	65
2.1 Local e procedimentos	65
2.2 Análises quantitativas e qualitativas	65
2.3 Análise espectral	67
2.4 Aprendizado de máquina	67
2.5 Análises estatísticas	68
3. RESULTADOS	70
4. DISCUSSÃO	72
5. CONCLUSÃO	76
REFERÊNCIAS	77
CAPÍTULO 5 – NOTA TÉCNICA	91

LISTA DE FIGURAS

Figura 1. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de pH.	
59Figura 2. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de cocção	59
Figura 3. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de maciez	60
Figura 4. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de IFM	60
Figura 5. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %MMb2	61
Figura 6. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %Mb+2	61
Figura 7. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %O2Mb2	62
Figura 8. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de L*(A)	62
Figura 9. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de a*(A)	63
Figura 10. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de b*(A)	63
Figura 11. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de C*	64
Figura 12. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de h*	64
Figura 13. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de pH para frango	82
Figura 14. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de cocção para frango	82
Figura 15. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de maciez para frango.	83
Figura 16. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de IFM para frango	83
Figura 17. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %MMb2 para frango	84
Figura 18. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %Mb+2 para frango	84
Figura 19. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %O2Mb2 para frango	85
Figura 20. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de L*(A) para frango	85
Figura 21. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de a*(A) para frango	86
Figura 22. . Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de b*(A) para frango	86
Figura 23. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de C* para frango	87
Figura 24. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de h* para frango	87
Figura 25. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de pH para suíno	88
Figura 26. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de cocção para suíno	88
Figura 27. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de maciez para suíno	89
Figura 28. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de IFM para suíno	89
Figura 29. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %MMb2 para suíno	90
Figura 30. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %Mb+2 para suíno	90
Figura 31. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %O2Mb2 para suíno	91
Figura 32. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de L*(A) para suíno	91
Figura 33. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de a*(A) para suíno	92
Figura 34. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de b*(A) para suíno	92
Figura 35. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de C* para suíno	93
Figura 36. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de h* para suíno	93

RESUMO

A crescente demanda por carne de qualidade, aliada à necessidade de métodos rápidos e não destrutivos de avaliação, tem impulsionado o desenvolvimento de novas tecnologias aplicadas à ciência da carne. Nesse contexto, objetivou-se avaliar a aplicação do aprendizado de máquina associada à espectroradiometria na classificação e caracterização de diferentes tipos de fibras musculares, bem como correlacionar essa abordagem com métodos convencionais de análise da qualidade da carne. No capítulo 1 foram utilizadas amostras de carne bovina, avaliando fibras musculares vermelhas por meio de análises físico-químicas convencionais e dados espectrais obtidos por espectroradiometria, objetivando identificar os algoritmos de aprendizado de máquina com maior capacidade preditiva para atributos qualitativos da carne. No capítulo 2 foram utilizadas amostras de carne suína e de frango, representando fibras oxidativa-glicolíticas e glicolíticas, respectivamente, objetivando avaliar o desempenho de diferentes algoritmos de aprendizado de máquina na predição de parâmetros qualitativos a partir de dados espectrais VIS-NIR. Foram determinados parâmetros físico-químicos e qualitativos, incluindo pH, coloração (L^* , a^* , b^* , C^* e h^*), maciez, perda por cocção, índice de fragmentação miofibrilar e frações de mioglobina. Paralelamente, foram obtidos dados espectrais por espectroradiometria, posteriormente submetidos a técnicas de pré-processamento e utilizados como variáveis de entrada em modelos de aprendizado de máquina. Os dados foram submetidos aos algoritmos redes neurais artificiais (RNA), REPTree (DT), árvore de decisão M5P, Random Forest (RF), máquina de vetores de suporte (SVM) e ZeroR, utilizado como controle. Os modelos foram validados por meio do coeficiente de correlação de Pearson (r) e erro absoluto médio (MAE). No capítulo 1, os modelos M5P e RF apresentaram melhor desempenho para as variáveis de pH, perda por cocção, maciez, IFM, pigmentos musculares e parâmetros de cor em fibras vermelhas. No capítulo 2, para as fibras glicolítica e oxidativa-glicolítica, os modelos DT destacaram-se para pH, enquanto M5P apresentou melhor desempenho para maciez e IFM. Para perda por cocção, DT apresentou melhor desempenho na fibra glicolítica, enquanto M5P, RF e SVM destacaram-se na fibra oxidativa-glicolítica. Para pigmentos musculares e parâmetros de cor, RF e M5P apresentaram os melhores resultados em ambas as fibras. De modo geral, a integração entre espectroradiometria e aprendizado de máquina mostrou-se promissora como método rápido, não destrutivo e aplicável na avaliação da qualidade da carne.

Palavras-chave: aprendizado de máquina; fibras musculares; espectroradiometria; métodos não destrutivos; qualidade da carne.

ABSTRACT

The increasing demand for high-quality meat, combined with the need for rapid and non-destructive evaluation methods, has driven the development of new technologies applied to meat science. In this context, this study aimed to evaluate the application of machine learning associated with spectroradiometry in the classification and characterization of different muscle fiber types, as well as to correlate this approach with conventional meat quality analysis methods. In Chapter 1, beef samples containing red muscle fibers were evaluated through conventional physicochemical analyses and spectral data obtained by spectroradiometry, aiming to identify machine learning algorithms with greater predictive capacity for meat quality traits. In Chapter 2, pork and chicken meat samples, representing oxidative-glycolytic and glycolytic fibers, respectively, were used to evaluate the performance of different machine learning algorithms in predicting qualitative parameters from VIS-NIR spectral data. Physicochemical and qualitative parameters were determined, including pH, color (L^* , a^* , b^* , C^* and h^*), tenderness, cooking loss, myofibrillar fragmentation index, and myoglobin fractions. Simultaneously, spectral data were obtained by spectroradiometry, submitted to preprocessing techniques, and used as input variables in machine learning models. The data were subjected to artificial neural networks (ANN), REPTree (DT), M5P decision tree, Random Forest (RF), support vector machine (SVM), and ZeroR, used as a control model. Model performance was validated using Pearson's correlation coefficient (r) and mean absolute error (MAE). In Chapter 1, the M5P and RF models showed superior performance for pH, cooking loss, tenderness, myofibrillar fragmentation index, myoglobin pigments, and color parameters in red fibers. In Chapter 2, DT models showed better performance for pH prediction in glycolytic and oxidative-glycolytic fibers, while M5P performed better for tenderness and myofibrillar fragmentation index. For cooking loss, DT showed superior performance in glycolytic fibers, whereas M5P, RF, and SVM achieved better results in oxidative-glycolytic fibers. For myoglobin pigments and color parameters, RF and M5P showed the best predictive performance in both fiber types. Overall, the integration of spectroradiometry and machine learning proved to be a promising rapid, non-destructive, and applicable method for meat quality evaluation.

Keywords: machine learning; muscle fibers; spectroradiometry; non-destructive methods; meat quality.

CAPÍTULO 1 – CONSIDERAÇÕES GERAIS

A produção e o abate de bovinos, aves e suínos têm apresentado crescimento contínuo nas últimas décadas, impulsionados pela expansão do setor pecuário e pelo aumento das exigências dos consumidores por alimentos de maior qualidade e com atributos sensoriais e nutricionais bem definidos. Em 2025, foram registrados abates de 42,94 milhões de bovinos (+8,2%), aproximadamente 6,69 bilhões de frangos (+3,1%) e 60,69 milhões de suínos (+4,3%), configurando recordes históricos (IBGE, 2026). Esse cenário evidencia a crescente demanda por metodologias capazes de avaliar, de forma eficiente, a qualidade da carne ao longo da cadeia produtiva.

Nesse contexto, a qualidade da carne tornou-se um fator determinante na decisão de compra, sendo influenciada por atributos como cor, maciez, suculência, capacidade de retenção de água e composição nutricional (Chen et al., 2023). Estudos recentes demonstram que características intrínsecas do músculo, especialmente a composição e proporção dos tipos de fibras musculares, exercem influência direta sobre esses atributos qualitativos, afetando tanto as propriedades físico-químicas quanto sensoriais da carne (Picard; Gagaoua, 2020; Matarneh et al., 2021).

As diferenças entre carnes bovina, suína e de aves estão relacionadas principalmente à estrutura muscular e à composição de fibras. A carne bovina apresenta predominância de fibras do tipo I, associadas ao metabolismo oxidativo e maior teor de mioglobina, o que resulta em coloração mais escura e características nutricionais relevantes, como alto teor de proteínas, vitaminas do complexo B e minerais (Sarcinelli et al., 2007). A carne suína apresenta perfil intermediário, com combinação de fibras oxidativas e glicolíticas, enquanto a carne de frango possui predominância de fibras glicolíticas, menor teor de mioglobina e elevada digestibilidade (Freitas, 2015; Sarcinelli et al., 2007).

Entre os atributos de qualidade, a maciez destaca-se como um dos principais fatores de aceitação pelo consumidor. Esse parâmetro está associado a fatores como tipo de fibra muscular, estrutura do tecido conjuntivo, atividade enzimática pós-morte e condições de processamento. Sua avaliação pode ser realizada por métodos sensoriais, baseados em painéis treinados, ou por métodos instrumentais, como o uso de texturômetros, que quantificam a força necessária ao cisalhamento da carne (Alves et al., 2005; Ramos; Gomide, 2007). Contudo, métodos tradicionais apresentam limitações, como caráter destrutivo, elevado tempo de análise e necessidade de mão de obra especializada.

Diante dessas limitações, observa-se uma crescente demanda por tecnologias rápidas, precisas e não destrutivas para avaliação da qualidade da carne. Nesse cenário, técnicas baseadas em espectroscopia e análise de imagens têm ganhado destaque, especialmente após o avanço da automação industrial e da inteligência artificial, que impulsionaram o desenvolvimento de sistemas mais eficientes de inspeção alimentar (Jia et al., 2018; Lan et al., 2020).

O aprendizado de máquina (Machine Learning – ML), associado a dados espectrais, surge como uma ferramenta promissora para a análise de padrões complexos relacionados à qualidade da carne. Essa abordagem permite a identificação de relações não lineares entre variáveis físico-químicas e espectrais, possibilitando previsões mais precisas de atributos como cor, pH, maciez e capacidade de retenção de água. Entretanto, o desempenho dos modelos depende do conjunto de dados e do tipo de algoritmo utilizado, sendo necessária a comparação entre diferentes técnicas para seleção do modelo mais adequado (Santana et al., 2023).

Assim, este trabalho teve por objetivo explorar o uso do aprendizado de máquina associado à espectroradiometria na predição da qualidade de diferentes tipos de fibras musculares, buscando correlações com métodos convencionais de avaliação.

1. INTRODUÇÃO

A produção e o abate de bovinos, aves e suínos têm crescido de forma constante nos últimos anos, impulsionados tanto pela expansão do setor pecuário quanto pelas novas exigências dos consumidores por produtos alinhados a valores sociais e às suas necessidades; em 2025, por exemplo, foram abatidos 42,94 milhões de bovinos (+8,2%), cerca de 6,69 bilhões de frangos (+3,1%) e 60,69 milhões de suínos (+4,3%), todos configurando recordes históricos (IBGE, 2026). Esse aumento na produção intensifica a necessidade de atender a um mercado cada vez mais exigente, no qual a qualidade da carne se destaca como critério central de decisão, levando os consumidores a considerarem não apenas atributos sensoriais, mas também valor nutricional, satisfação alimentar e conveniência do produto (Chen et al., 2023).

Dessa forma, compreender os fatores que influenciam a qualidade da carne é fundamental. Estudos recentes demonstram que as características musculares, especialmente a composição dos tipos de fibras musculares, estão diretamente associadas aos atributos de qualidade da carne, como cor, maciez e capacidade de retenção de água (Picard & Gagaoua, 2020). Além disso, propriedades metabólicas e estruturais do músculo influenciam as alterações bioquímicas pós-morte durante a conversão do músculo em carne, afetando diretamente a qualidade final do produto (Matarneh et al., 2021).

As diferenças entre carnes bovina, suína e de aves estão relacionadas principalmente à estrutura e composição de suas fibras musculares, o que afeta textura, sabor, digestibilidade e tempo de cocção. A carne bovina, classificada como carne vermelha, possui predominância de fibras do tipo I, de contração lenta, maior resistência à fadiga e elevado teor de mioglobina, o que resulta em coloração mais escura. É também importante fonte nutricional, fornecendo proteínas, lipídeos, vitaminas do complexo B e minerais, especialmente zinco e ferro, este último em forma de alta biodisponibilidade (Sarcinelli et al., 2007).

A carne suína, embora também classificada como carne vermelha, é descrita como intermediária por conter proporções equilibradas de fibras oxidativas e glicolíticas. Suas fibras musculares dos tipos I e II determinam características como coloração, velocidade de contração e composição (Freitas, 2015).

A carne de frango, por sua vez, destaca-se pelo menor teor de gordura e pelo alto valor proteico, sendo amplamente consumida por sua praticidade e preço acessível. Apresenta maior proporção de fibras glicolíticas, especialmente na região do peito, e menor teor de mioglobina (Sarcinelli et al., 2007; Ganeco, 2016).

A maciez que é influenciada pelo tipo ou proporção de fibras musculares, destaca-se

como uma das características mais importantes na percepção de qualidade pelo consumidor. Sua avaliação pode ser realizada por métodos subjetivos ou objetivos. O método subjetivo baseia-se em painéis sensoriais treinados, que classificam a maciez após a degustação das amostras. Já os métodos objetivos empregam equipamentos como o texturômetro, que quantifica a força necessária para o cisalhamento das fibras, sendo maior força associada a menor maciez (Alves et al., 2005; Ramos e Gomide, 2007). Além desses, surgem métodos alternativos baseados em espectroscopia e análise instrumental, que vêm ganhando destaque por fornecerem estimativas rápidas e não destrutivas, constituindo o foco inovador deste estudo com diferentes tipos de fibras musculares.

Nesse cenário, cresce a busca por tecnologias capazes de reduzir o tempo de análise sem comprometer a precisão. Assim, o aprendizado de máquina surge como uma alternativa inovadora para o setor de alimentos, permitindo análises rápidas e eficazes (Santana et al., 2024). O rápido crescimento da conscientização pública e da preocupação com a qualidade superior da carne tem impulsionado o desenvolvimento de técnicas não destrutivas baseadas em espectroscopia e imagem. A necessidade de reduzir o contato humano com alimentos, intensificada após a pandemia de COVID-19, somada ao avanço da automação e da Inteligência Artificial na indústria alimentícia, tem favorecido a substituição de métodos destrutivos por abordagens rápidas e confiáveis. Dessa forma, tecnologias baseadas em imagem e em diferentes regiões do espectro eletromagnético, como computação visual (CV), espectroscopia e imagem multiespectral/hiperespectral (MSI), vêm sendo aplicadas para avaliação da qualidade da carne, permitindo análises *on-line* e *in-line* com elevado potencial de precisão (Jia et al., 2018; Lan et al., 2020).

Assim, técnicas de aprendizado de máquinas (Machine Learning – ML), associadas aos dados espectrais, permitem identificar padrões complexos e realizar previsões precisas relacionadas à qualidade da carne. Essa abordagem representa uma alternativa promissora para modernizar e agilizar análises, possibilitando avaliações rápidas e não destrutivas de atributos como cor, maciez, composição química e capacidade de retenção de água. Além disso, os algoritmos de ML podem identificar relações e informações que métodos tradicionais muitas vezes não conseguem detectar, contribuindo para processos de classificação e tomada de decisão mais eficientes e confiáveis. Entretanto, o desempenho dos algoritmos varia conforme o conjunto de dados utilizado, sendo necessária a avaliação de diferentes modelos para determinar o classificador mais adequado para cada aplicação (Santana et al., 2023).

Dessa forma, este trabalho teve por objetivo explorar o uso do aprendizado de máquina associada à espectroradiometria para obter informações inovadoras, rápidas e precisas na

classificação e avaliação de diferentes tipos de fibras musculares.

2. REVISÃO DE LITERATURA

2.1 Parâmetros qualitativos das fibras musculares avaliadas

A carne não é apenas uma fonte relevante de aminoácidos, minerais e vitaminas, mas também constitui um alimento de elevado valor energético (Rendle e Keeley, 1998). Além de seu valor nutricional, a carne é avaliada pelo consumidor com base em atributos sensoriais, dentre os quais a cor se destaca como o principal fator determinante da aceitação e da decisão de compra. A tonalidade vermelho-brilhante é geralmente associada à percepção de frescor e qualidade. Entretanto, observa-se que a coloração da carne tende a escurecer com o avanço da idade dos animais, em decorrência do aumento da concentração de mioglobina nos tecidos musculares (Wu et al., 2020; Tomasevic et al., 2021; Salim et al., 2022; Altmann et al., 2023).

A cor da carne de frango é medida instrumentalmente por meio do sistema CIELAB, que expressa a luminosidade (L^*), o componente de vermelhidão (a^*) e o de amarelecimento (b^*) (Tomasevic e Rajkovic, 2015). A variação desses parâmetros decorre de múltiplos fatores intrínsecos e extrínsecos, sendo os pigmentos musculares o principal determinante da coloração. Dentre esses pigmentos, destacam-se a mioglobina (Mb), a hemoglobina (Hb), o citocromo C e seus derivados, embora a Mb seja reconhecida como o componente majoritário responsável pela coloração da carne de aves (Faustman et al., 2010).

A coloração da carne bovina é fortemente influenciada pelo pH *post mortem*. Após o abate, a interrupção do suprimento de oxigênio leva à glicólise anaeróbia, com consequente produção de ácido lático e redução do pH muscular. Valores finais de pH entre 5,4 e 5,9 estão associados à carne mais clara, brilhante e com menor estabilidade oxidativa. Em contrapartida, quando o pH permanece elevado ($\geq 6,0$), a carne apresenta coloração mais escura e maior estabilidade, uma vez que o pH modula a atividade enzimática e os processos de oxigenação dos pigmentos musculares (Toldrá, 2006; Boles e Pegg, 2001).

As variações na cor da carne estão diretamente relacionadas aos diferentes estados químicos da mioglobina, proteína responsável pelo transporte e armazenamento de oxigênio no músculo. Em condições de baixa disponibilidade de oxigênio, a mioglobina encontra-se na forma reduzida, conferindo coloração vermelho-arroxeadas. Na presença de oxigênio, ocorre a formação de oximioglobina, responsável pela coloração vermelho-brilhante característica da carne fresca. Assim, elevados teores de oximioglobina são considerados indicadores positivos de qualidade, enquanto a predominância de formas oxidadas, associadas à coloração marrom, representa um atributo negativo para a aceitação do produto pelo consumidor (Varnam e Sutherland, 1995).

Em aves, especificamente na carne de frango, a influência do pH sobre a cor está mais relacionada às alterações estruturais das fibras musculares do que à concentração absoluta de mioglobina. Valores reduzidos de pH ($\leq 5,9$) promovem maior espaçamento entre as miofibrilas, aumentando a dispersão da luz e resultando em coloração mais clara. Por outro lado, pH elevado ($\geq 6,2$) favorece a compactação das fibras musculares, reduzindo a difusão de oxigênio e a penetração da luz, o que confere aparência mais escura ao músculo (Komiayama, 2010).

Para a carne suína, fibra oxidativa-glicolítica em composição e estrutura muscular, o padrão ideal é o RFN (Red, Firm and Non-exudative), caracterizado por coloração rosada a vermelho-claro, gordura branca firme e baixa exsudação. Essas carcaças apresentam pH inicial mais elevado ($\approx 6,0$ – $6,5$), seguido de pH final entre 5,5 e 5,9, além de temperatura muscular inicial inferior a 40 °C, posicionando-se como fibras glicolítica e oxidativa (Sarcinelli et al., 2007; Terra, 1998; Amin et al., 2014).

Segundo Warner et al. (1997), a carne suína com coloração considerada normal deve apresentar valores de luminosidade (L^*) inferiores a 50. Em contrapartida, Warris e Brown (1995), por meio da “Meat and Livestock Commission”, vinculada à American Meat Science Association (AMSA), classificam carnes com valores de L^* entre 49 e 60 como estando dentro dos padrões aceitáveis de qualidade para suínos. Essa amplitude reflete as variações naturais entre lotes, condições pré-abate e diferenças no metabolismo muscular.

Diversos estudos têm atribuído efeitos significativos da dieta e do manejo pré-abate sobre a coloração da carne. Acevedo-Giraldo et al. (2020), ao investigarem o tempo de jejum em suínos, observaram maiores valores de L^* em períodos de jejum mais curtos, sugerindo menor depleção de glicogênio muscular e consequente acidificação mais rápida após o abate. Em bovinos Nelore, Silva et al. (2019) relataram que maiores períodos de confinamento aprimoram a qualidade da carcaça e da carne, incluindo a coloração. Esses autores verificaram que animais abatidos sem período de confinamento apresentaram menor teor de gordura intramuscular, o que pode explicar a redução na luminosidade (L^*) e na intensidade de amarelo (b^*), em comparação com animais confinados por 100 ou 200 dias.

Além disso, as menores intensidades de vermelho (a^*) observadas em bovinos mais leves e jovens foram atribuídas ao menor teor de mioglobina, pigmento cuja concentração aumenta com a idade e a atividade muscular (Silva et al., 2019). Em relação ao tipo de dieta, Li et al. (2020) demonstraram que a inclusão de extrato de polifenóis de folhas de eucalipto na alimentação de frangos elevou os valores de a^* e a concentração de mioglobina do músculo peitoral, possivelmente devido ao aumento da capacidade antioxidante da carne, resultando em

maior preservação dos pigmentos heme.

A mioglobina (Mb) é a principal responsável pela cor da carne de frango. Sua estrutura é composta por uma cadeia polipeptídica, com várias moléculas de histidina e globina. (Silverstein et al., 2015; Mancini e Hunt, 2005). A integridade estrutural da globina desempenha papel fundamental ao evitar a oxidação do ferro heme, preservar a conformação tridimensional da proteína e garantir a solubilidade do complexo heme em meio aquoso (Suman et al., 2013).

Vários estados redox do magnésio (Mg) indicam carne fresca. Esses estados são: desoximioglobina (DeoxyMb), de coloração vermelho-arroxeadas; oximioglobina (OxyMb), vermelho-cereja; carboximioglobina (COMb), vermelho intenso; e metamioglobina (MetMb), de coloração marrom, típica de processos oxidativos avançados (O'Sullivan, 2017).

A aceitabilidade visual da carne é reduzida quando a O₂Mb responsável pela característica cor vermelho-cereja desejada pelo consumidor sofre oxidação e é convertida em Mmb (cor marrom inaceitável). Estudos comparativos em frangos, indicam que o teor de Mb é significativamente menor no músculo peitoral quando comparado à coxa e à perna (Fleming et al., 1991; Boulianne e King, 1998; Wideman et al., 2016). Tal diferença decorre da composição das fibras musculares: a musculatura da coxa e da perna é composta predominantemente por fibras oxidativas (fibras vermelhas), com maior densidade capilar e concentração de pigmentos heme, enquanto o músculo peitoral é constituído predominantemente por fibras glicolíticas (fibras glicolítica), com menor concentração de Mb (Suman et al., 2013). De acordo com Jiang et al. (2014), músculos como o adutor da coxa e o sartório apresentam teores significativamente superiores de Mb e heme total quando comparados ao músculo peitoral maior.

Boulianne e King (1998) observaram que amostras de carne de peito com coloração excessivamente escura apresentavam maiores concentrações de heme total e mioglobina (Mb) (1,47 e 0,16 mg/g), quando comparadas às amostras de coloração considerada normal (0,96 e 0,12 mg/g), respectivamente. Esses achados evidenciam a forte correlação entre os valores de luminosidade (L*) e a concentração de pigmentos heme, reforçando o papel da Mb como principal determinante da coloração da carne de frango. No entanto, além da concentração de pigmentos, outros fatores físico-químicos, especialmente o pH *post mortem*, exercem influência direta tanto sobre a cor quanto sobre as propriedades funcionais da carne.

A queda do pH *post mortem* afeta diretamente as proteínas musculares, impactando simultaneamente a formação da cor final e a capacidade de retenção de água (CRA). À medida que o pH se aproxima do ponto isoelétrico das proteínas miofibrilares, ocorre neutralização das cargas elétricas responsáveis pela ligação da água às proteínas, resultando na sua liberação. Esse processo contribui para o aumento das perdas de líquido durante as etapas de corte,

armazenamento, processamento e preparo da carne. Em condições extremas, como na carne do tipo PSE (pálida, mole e exsudativa), esses efeitos são intensificados, levando a perdas ainda mais expressivas (Bernardes e Prata, 2001).

A capacidade de retenção de água constitui uma das principais propriedades funcionais das proteínas musculares e desempenha papel determinante na qualidade tecnológica e sensorial da carne, especialmente após o cozimento. Essa propriedade é definida como a capacidade do tecido muscular em reter sua água intrínseca quando submetido a forças externas, tais como aquecimento, trituração, prensagem e cortes mecânicos (Judge et al., 1989). Segundo os mesmos autores, maiores valores de CRA estão associados a maior suculência e melhor percepção sensorial de maciez.

Além dos efeitos sensoriais, a CRA influencia diretamente o valor econômico e nutricional da carne, uma vez que sua redução pode ocasionar prejuízos ao longo da cadeia produtiva, desde o armazenamento até a comercialização. A exsudação excessiva resulta não apenas em menor rendimento do produto final, mas também na perda de componentes hidrossolúveis, como proteínas, peptídeos, aminoácidos, ácido lático, purinas e vitaminas do complexo B, comprometendo a qualidade nutricional do alimento (Cheftel et al., 1986).

As proteínas miofibrilares são responsáveis por aproximadamente 75% da capacidade de retenção de água da carne (Judge et al., 1989). Dessa forma, quaisquer fatores que afetem sua estrutura ou funcionalidade repercutem diretamente sobre a CRA. Entre os principais fatores destacam-se novamente o pH muscular, o estado de contração das fibras e o grau de desnaturação das proteínas miofibrilares, os quais atuam de forma integrada na determinação da qualidade final da carne.

Explicitando os principais defeitos relacionados à aparência da carne, destacam-se as condições DFD e PSE, facilmente percebidas no produto final. A carne DFD (dark, firm and dry) apresenta pH elevado, coloração escura e maior suscetibilidade à deterioração microbiana (Sañudo, 2000). Já a carne PSE (pale, soft and exudative) resulta de uma queda rápida do pH pós-morte ($\leq 5,9$), caracterizando-se por palidez, textura amolecida e baixa capacidade de retenção de água (Honikel, 1998). Considerando que o músculo possui pH aproximado de 7,2 (NPPC, 1998), o padrão desejável para a maioria das espécies é o RFN, que representa carnes de coloração normal, firmes e não exsudativas.

Em estudo realizado por da Silva, de Arruda e Gonçalves (2017), foram avaliados parâmetros clássicos de qualidade da carne de frango proveniente de sistemas de criação industrial e extensivo. A comparação entre os sistemas foi baseada em análises de cor, pH e composição centesimal. Os resultados indicaram a ocorrência da anomalia PSE (pálida, macia

e exsudativa) em ambos os sistemas de produção, com valores de luminosidade (L^*) superiores a 53. A carne de frango oriunda do sistema extensivo apresentou maior intensidade de coloração amarela (b^* 11,56) e maior força de cisalhamento (2,75 kg), indicando menor maciez, quando comparada à carne de frango industrial. Por outro lado, valores inferiores de intensidade de vermelho (a^* 1,65) e pH (5,75) foram observados na carne proveniente do sistema extensivo.

A maciez da carne é outro fator que está ligado diretamente a fidelidade do consumidor. Esse parâmetro está relacionado ao desenvolvimento próprio da musculatura do animal, raça, idade, sexo, sistema de criação, dieta, manejo pré-abate e pós-abate, bem-estar, fatores pós-morte como a queda de pH, resfriamento e manipulação da carcaça (Picard, Gagaoua, 2020; Naqvi et al., 2021).

Em aves, carnes que apresentam valores reduzidos de pH caracterizam-se por menor capacidade de retenção de água (CRA), o que resulta em maiores perdas por cozimento e gotejamento, além de comprometer a maciez do produto final (Popova, 2017). O estresse pré-abate, especialmente decorrente da luta ou agitação das aves, promove a depleção do glicogênio muscular. Consequentemente, após o abate, a glicólise ocorre de forma limitada, levando a menor produção de ácido láctico e, portanto, à elevação do pH final da carne (Mir et al., 2017).

A maciez da carne suína é um dos principais atributos de qualidade percebidos pelo consumidor e resulta da interação entre fatores estruturais, bioquímicos e físico-químicos do tecido muscular. Esse atributo está diretamente relacionado à organização das fibras musculares, à integridade das proteínas miofibrilares e às alterações ocorridas no período *pós-mortem* (Koomaraie 1996; Ramos; Gomide, 2007).

Após o abate, a glicólise anaeróbia promove a redução do pH muscular, desencadeando modificações na estrutura do músculo, como a dissociação parcial do complexo actomiosina. Concomitantemente, sistemas proteolíticos endógenos, especialmente as calpaínas, atuam na degradação de proteínas estruturais, como desmina, titina e nebulina, enfraquecendo a coesão entre as miofibrilas e favorecendo o amaciamento da carne (Huff-lonergan; Lonergan, 2005; Koohmaraie; Geesink, 2006).

As propriedades reológicas da carne refletem diretamente essas alterações estruturais. Carnes mais macias apresentam menor módulo elástico e menor força de cisalhamento, indicando uma estrutura muscular menos rígida e mais susceptível à deformação mecânica. Estudos recentes demonstram que mudanças físico-químicas nas proteínas miofibrilares estão intimamente associadas à redução da resistência ao cisalhamento e ao aumento da maciez da carne suína (Ramos; Gomide, 2009; Lwt, 2025).

Portanto, a maciez da carne suína deve ser compreendida como um atributo multifatorial, determinado pela ação coordenada de processos bioquímicos *pós-mortem*, características estruturais do músculo e propriedades físico-químicas e reológicas, conforme evidenciado por estudos clássicos e recentes na ciência da carne (Koohmaraie, 1996; Huff-lonergan; Lonergan, 2005; Ramos; Gomide, 2007).

A análise de perda por cocção (PPC) é um parâmetro fundamental na avaliação da qualidade da carne, uma vez que simula condições semelhantes às do consumo final. Durante o aquecimento, ocorrem alterações físicas e bioquímicas, como a liberação de água e a desnaturação das proteínas musculares, que podem afetar não apenas as características sensoriais, mas também a qualidade microbiológica, a digestibilidade e o valor nutritivo do produto (Bejerholm et al., 2014; Monte et al., 2012).

Para a correta avaliação da PPC, é necessário considerar que os métodos empregados no processo de cocção podem interferir significativamente no resultado final da carne, especialmente no que se refere à maciez. Dessa forma, a análise de perda por cocção é, geralmente, realizada previamente às avaliações de maciez, uma vez que ambos os parâmetros estão diretamente relacionados (Bejerholm et al., 2014; Fabre et al., 2018; Ramos e Gomide, 2007).

Diversos fatores podem influenciar a PPC, incluindo o genótipo do animal, as condições de manejo pré e pós-abate e os procedimentos adotados durante o preparo das amostras. Aspectos como a remoção ou manutenção da gordura subcutânea e o tipo de equipamento utilizado no cozimento podem alterar a taxa de aquecimento e a temperatura final atingida pela carne, impactando diretamente as perdas por cocção (Silva et al., 2008).

A taxa de cocção exerce papel determinante no amaciamento enzimático da carne, uma vez que as enzimas responsáveis por esse processo são progressivamente inativadas em temperaturas superiores a 55 °C. Taxas de aquecimento elevadas reduzem o tempo de exposição da carne a temperaturas próximas ao ideal para a atividade enzimática, limitando sua ação sobre as estruturas miofibrilares e, conseqüentemente, sobre a maciez (Ramos e Gomide, 2009).

Nesse contexto, Hughes et al. (2014) demonstraram que a perda por cocção ocorre principalmente na faixa de temperatura entre 45 °C e 70–80 °C, estabilizando-se em temperaturas superiores a 80 °C. Segundo esses autores, a maior parte da água perdida durante o cozimento resulta do extravasamento do suco muscular, provocado pela desnaturação das proteínas e pela contração das estruturas musculares, fenômenos que variam de acordo com a temperatura aplicada durante o processo térmico.

A avaliação da qualidade das fibras musculares inicia-se pelo controle da matéria-

prima *in natura*. A inspeção visual permite a estimativa de atributos sensoriais, como cor, aparência e odor, enquanto a avaliação do sabor é realizada posteriormente por meio de análises sensoriais. Grande parte dessas avaliações ainda depende de painéis sensoriais treinados, uma vez que não existem métodos laboratoriais ou dispositivos mecânicos capazes de reproduzir integralmente as ações de mordida e mastigação, bem como todas as percepções sensoriais humanas envolvidas nesse processo (Juárez et al., 2012). No entanto, a qualidade das fibras frescas também pode ser determinada por métodos instrumentais, que incluem a análise da composição e dos parâmetros nutricionais, da cor, da capacidade de retenção de água, do teor de gordura, da maciez, da funcionalidade, além da avaliação de deterioração e contaminação microbiológica (Joo et al., 2013).

2.2 Avaliação qualitativa da carne: abordagens convencionais e das inovações em espectroscopia e aprendizado de máquina

A qualidade da carne é caracterizada por análises centesimais, sensoriais e também por análises físico-químicas, como maciez, coloração, pH e perda de peso por cozimento (cocção) e IFM, que são de grande importância como determinadores de visual e aceitabilidade sensorial da carne (Cruz et al., 2016). Análises estas, que são de grande importância também para a indústria, podendo trazer uma redução de perdas de produtos devido as cores indesejáveis ou por perda de peso, seja por cozimento, degelo ou perdas exsudativas (Hughes et al., 2014).

Os métodos tradicionais de avaliação da qualidade da carne incluem métodos subjetivos e objetivos, a saber, a avaliação sensorial e técnicas físico-químicas. Esses métodos medem diversas características da carne, incluindo o conteúdo sensorial e nutricional. A eficácia e a precisão desses testes foram comprovadas ao longo do tempo (mais de 90%). No entanto, os métodos tradicionais apresentam muitas desvantagens, como a destrutividade, o trabalho árduo, o longo tempo de avaliação, o impacto ambiental dos resíduos químicos e a necessidade de pessoal altamente treinado para suas operações (Khaled et al., 2021).

As desvantagens dos métodos tradicionais destacam a necessidade de métodos mais rápidos, precisos e não destrutivos que possam ser usados em carnes e produtos cárneos para avaliar a qualidade e a segurança. Para uma instalação moderna de processamento de carnes, é essencial ter técnicas de detecção que atendam a essas necessidades, com a máxima capacidade de paralelização e automação que os limites tecnológicos e econômicos permitirem (Zhang et al., 2017).

Em resposta às desvantagens mencionadas, técnicas não destrutivas ganharam muita atenção nos últimos anos, com rápidos avanços. Pesquisadores desenvolveram diversas técnicas avançadas, incluindo CV (visão computacional) (Bhargava et al., 2020; Geronimo et al., 2019;

TaheriGaravand et al., 2019), espectroscopia (de Nadai Bonin et al., 2020; Rady et al., 2018; Wang et al., 2018), imagem hiperespectral (HSI) (Rady et al., 2020; Siripatrawan, 2018) e imagens multiespectrais (MSI) (Sendin et al., 2018; Su et al., 2018). Essas técnicas emergentes têm méritos em relação aos métodos convencionais, pois podem ser não destrutivas, rápidas e têm o potencial de serem aplicadas como um método de detecção no local (Balage et al., 2015; Velásquez et al., 2017).

Técnicas espectroscópicas associadas a ferramentas quimiométricas têm se mostrado promissoras na avaliação da autenticidade e, conseqüentemente, da qualidade da carne. Nesse contexto, diferentes estudos têm explorado o uso da espectroscopia no infravermelho com transformada de Fourier (FTIR) como ferramenta para a determinação de atributos de qualidade em produtos cárneos. Além disso, a espectroscopia de fluorescência tem demonstrado elevada eficiência na detecção de diversos tipos de adulterantes, tanto de origem vegetal quanto animal, presentes na carne. A adoção dessas técnicas como métodos rápidos de detecção, especialmente em países em desenvolvimento, representa uma estratégia relevante para o combate às fraudes na comercialização de carne, contribuindo para o aumento da confiança do consumidor e para a proteção da saúde pública (Candogan et al., 2021; Rohman et al., 2020; Cartín-Rojas, 2017; Maritano et al., 2024).

Detalhando um pouco sobre as novas técnicas, a computação visual (CV) é uma tecnologia emergente usada para a detecção e avaliação de atributos de qualidade externa em muitos produtos agrícolas (Barbin et al., 2016; Zhang et al., 2015). O CV coleta e analisa informações espaciais obtidas a partir de imagens digitais de amostras como cor, tamanho e estrutura de superfície (Girolami et al., 2013). Atualmente, as aplicações de CV limitam-se principalmente por detecção de superfícies.

Normalmente, um sistema de CV consiste em uma câmara de iluminação, uma fonte de luz, um computador e software. O CV tem três modos de detecção diferentes: reflectância, absorção e transmissão (Taheri-Garavand, Fatahi, Shahbazi, et al., 2019). Muitos fatores determinam a resposta da luz em um objeto medido, como o comprimento de onda e a penetração da luz incidente, as propriedades físicas e químicas do objeto e o índice de refração da amostra (Barbin et al., 2016). Assim, ter iluminação suficiente na superfície do objeto pode permitir melhor contraste e detecção de bordas, o que pode ajudar a câmera na detecção de características da superfície.

Segundo Khaled et al. (2021), mais estudos são apresentados mostrando diferentes maneiras de usar a CV para realizar a avaliação da qualidade da carne. Esses resultados indicam que a CV pode ser usada como uma ferramenta não destrutiva para avaliar a qualidade e a

segurança da carne em linhas de produção; no entanto, sua capacidade de detectar diferenças sutis de cor ou textura, igualmente importantes para a certificação geral da qualidade da carne, precisa ser significativamente aprimorada.

A técnica de espectroscopia considera-se uma das técnicas mais promissoras, devido ao seu mérito em relação as muitas abordagens analíticas (Khaled et al., 2018). Um sistema de espectroscopia típico consiste em quatro componentes: dispositivos de amostragem, fotodetector, mecanismos de isolamento de luz e uma fonte de luz. Em espectroscopia, existem três modos diferentes de aquisição de dados: interactância, refletância e transmitância. As localizações relativas do detector e da fonte de luz determinam o modo. Esses modos têm influência direta na banda passante do comprimento de onda, sendo a banda passante estreita no modo de transmissão e ampla no modo de refletância (Khaled et al., 2021).

Fang et al. (2015) identificaram quatro comprimentos de ondas nas aplicações em carnes: visível (VIS), infravermelho próximo (NIR) e infravermelho médio (MIR). A Sociedade Americana de Testes e Materiais (ASTM) quantificou essas diferentes regiões, onde a faixa de comprimento de onda da fluorescência abrange de 100 a 400 nm, VIS de 400 a 750 nm, NIR de 780 a 2500 nm e MIR de 2500 a 25.000 nm.

As análises de reflectância espectral têm se destacado como ferramentas relevantes na avaliação da qualidade da carne, uma vez que alterações na absorção da luz incidente em regiões específicas do espectro eletromagnético variam de acordo com os constituintes presentes no tecido analisado. Estudos recentes demonstram a eficácia da espectroscopia na detecção de parâmetros físico-químicos da carne (Barbon et al., 2018; de Nadai Bonin et al., 2020; Savoia et al., 2020; Wang et al., 2018). Entre os atributos de qualidade avaliados por essa técnica destacam-se: força de cisalhamento, conteúdo de gordura intramuscular (IMF), nitrogênio básico volátil total (TVB-N) e substâncias reativas ao ácido tiobarbitúrico na carne bovina; contagem total de microrganismos viáveis (TVC) e TVB-N na carne suína; além de perda por gotejamento, teor de umidade, métodos não destrutivos de avaliação da qualidade, atividade de água, TVB-N e trifosfato de adenosina em aves (Khaled et al., 2021).

As técnicas de imagem hiperespectral podem fornecer não apenas informações espaciais, como sistemas de imagens regulares, mas também informação espectral para cada pixel em uma imagem. Essa informação formará um “hipercubo” tridimensional que pode ser explorado para determinar alterações físicas menores e/ou sutis e características químicas em um objeto. As técnicas de imagem hiperespectral fornecem simultaneamente informações espaciais e espectrais de um objeto, formando um hipercubo tridimensional de dados. Essa abordagem possibilita a extração de características físicas, como cor, tamanho, forma e textura,

além da estimativa de propriedades químicas relacionadas à composição dos produtos, como água, gordura e proteína (Qião et al., 2007).

Recentemente, foram relatados diversas pesquisas de imagens hiperespectrais onde Kim et al. (2001) introduziram um sistema de imagem de reflectância hiperespectral e fluorescência para qualidade e segurança dos alimentos. Cheng et al. (2004) estudaram um método para inspecionar danos em pepinos por hiperespectral imagem. Também foi possível utilizar o sistema de imagem hiperespectral para inspecionar a contaminação de carcaças de frango (Kim et. al 2004).

Mais recentemente, avanços significativos têm sido relatados, evidenciando o potencial da espectroscopia e da imagem hiperespectral associadas a técnicas de aprendizado de máquina na avaliação de qualidade de carnes e autenticação de produtos. Estudos como os de Naganathan et al. (2015), ElMasry et al. (2012), Wojnowski et al. (2022) e González-Martín et al. (2023) demonstram que essas abordagens permitem análises rápidas, não destrutivas e com elevado potencial de aplicação em ambientes industriais, reforçando sua relevância como alternativa aos métodos convencionais.

Ainda detalhando sobre as técnicas, existe também a avaliação por imagem multiespectral. Sendo esta, uma tecnologia promissora e inovadora que tem sido utilizada na inspeção de carnes cruas e processadas (Ma et al., 2013). Normalmente, o MSI usará entre três e 15 comprimentos de onda, que são discretos, não contíguos e irregularmente espaçados (Feng et al., 2018). Ter uma maior qualidade e uma menor quantidade de informação a processar permite que a MSI alcance um desempenho, identificação e detecção mais rápidas (Su et al., 2018). O sistema MSI captura imagens tridimensionais (um espectro unidimensional $[\lambda]$ em cada pixel bidimensional $[x, y]$), que contêm informações heterogêneas que refletem as características físico-químicas da carne (Ma et al., 2016).

Luo et al. (2022) avaliaram a qualidade da carne bovina a partir de suas propriedades viscoelásticas, empregando técnicas de processamento de imagens tridimensionais (3D) de fluxo de ar associadas a algoritmos de inteligência artificial. Para a predição de parâmetros relacionados ao frescor da carne, os autores desenvolveram modelos de regressão baseados em características viscoelásticas. Diferentes abordagens foram testadas, incluindo regressão por árvore de decisão (DTR), regressão por máquina de vetores de suporte (SVM), redes neurais artificiais do tipo retropropagação (BPNN) e regressão por mínimos quadrados parciais (PLSR). Os resultados indicaram que os modelos baseados em SVR e BPNN apresentaram desempenho superior na predição dos atributos de frescor da carne.

Sun et al. (2012) investigaram a predição da maciez da carne bovina a partir de

parâmetros de textura obtidos por imagens coloridas e multiespectrais. Para a construção dos modelos preditivos, foram empregadas técnicas de máquina de vetores de suporte e regressão múltipla stepwise. Os resultados demonstraram que o algoritmo SVM apresentou desempenho superior em relação aos demais métodos, alcançando acurácia de 100% na predição baseada em imagens coloridas e de 91% quando utilizadas imagens multiespectrais, evidenciando o elevado potencial dessas abordagens para a avaliação objetiva da maciez da carne.

A principal aplicação do MSI na avaliação de carnes tem sido a avaliação da qualidade e segurança dos produtos (Alshejari et al., 2017; Estelles-Lopez et al., 2017; Ropodi et al., 2018). Aplicações específicas incluem avaliação da qualidade da carne moída congelada (Ropodi et al., 2018), previsão do teor de ferro heme e não heme em salsicha de porco (Ma et al., 2016) e detecção de adulteração em filés de peito de frango (Spyrelli et al., 2021).

É possível observar que o uso combinado de MSI e aprendizado de máquina apresenta elevado potencial para complementar ou até substituir métodos convencionais de análise, especialmente em sistemas que demandam rapidez, eficiência e aplicação em linha de processamento industrial.

2.3 Sensores hiperespectrais

Qualquer corpo com temperatura acima do zero absoluto emite energia eletromagnética, podendo ser considerado uma fonte de energia. Essa energia distribui-se ao longo do espectro eletromagnético em diferentes comprimentos de onda e frequências (Moraes, 2002). A interação da radiação eletromagnética com os materiais ocorre de maneira distinta, fazendo com que cada material apresente uma assinatura espectral própria, relacionada à absorção, reflexão ou transmissão da energia incidente (Figueiredo, 2005).

Os sensores espectrais captam essas variações da radiação eletromagnética e transformam as informações obtidas em dados passíveis de interpretação (NAUE et al., 2011). No contexto da qualidade da carne, essa tecnologia permite identificar diferenças físico-químicas relacionadas à composição muscular, teor de água, gordura, proteínas e coloração, por meio da análise da resposta espectral do produto.

Dentro do sensoriamento espectral, os sensores podem ser classificados em multiespectrais e hiperespectrais, de acordo com sua resolução espectral. Sensores multiespectrais capturam informações em bandas específicas do espectro eletromagnético, enquanto sensores hiperespectrais adquirem bandas estreitas e contínuas ao longo do espectro, fornecendo uma quantidade muito maior de informações (YANG et al., 2017). Essa elevada resolução espectral possibilita análises mais detalhadas e precisas das características da carne,

favorecendo aplicações relacionadas à classificação, autenticação e avaliação de qualidade.

Além disso, sensores hiperespectrais associados a técnicas de aprendizado de máquinas têm sido amplamente utilizados para análises rápidas e não destrutivas, permitindo identificar padrões espectrais associados a atributos tecnológicos e sensoriais da carne. Em comparação às câmeras Red, Green e Blue (RGB) convencionais, que capturam apenas informações nas bandas do vermelho, verde e azul, os sensores hiperespectrais fornecem informações espectrais adicionais capazes de detectar características que não são visíveis ao olho humano (Tait et al., 2019).

3. OBJETIVOS

3.1 Objetivo Geral

Avaliar o aprendizado de máquina aplicada à espectroradiometria na predição de qualidade dos diferentes tipos de fibras musculares, correlacionando essa abordagem às análises qualitativas obtidas por meio de metodologias convencionais.

3.2 Objetivos Específicos

Avaliar os parâmetros qualitativos (pH, coloração, maciez e IFM) utilizando as metodologias convencionais nos músculos *Longissimus dorsi* (bovino), *Pectoralis major* (peito de frango) e *Longissimus dorsi* (suíno).

Avaliar o potencial da espectroradiometria associada ao aprendizado de máquina na caracterização das fibras musculares.

Determinar a eficiência e a precisão das técnicas espectrais e dos modelos de aprendizado de máquina como ferramentas complementares ou alternativas às metodologias convencionais.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABRIL, M. et al. Beef color evolution as a function of ultimate pH. *Meat Science*, v. 58, n. 1, p. 69–78, 2001.
- ACEVEDO-GIRALDO, J. D. et al. Effects of feed withdrawal time before slaughter on animal welfare indicators and meat quality traits in commercial pigs. *Meat Science*, v. 167, p. 107993, 2020.
- ALSHEJARI, A.; KODOGIANNIS, V. S. An intelligent decision support system for meat spoilage detection using multispectral images. *Neural Computing and Applications*, v. 28, n. 12, p. 3903–3920, 2017.
- ALTMANN, B. A. et al. Consumer preferences for the color of unprocessed animal foods. *Journal of Food Science*, 2023. Disponível em: <https://doi.org/10.1111/1750-3841.16485>. Acesso em: 15 jun. 2024.
- ALVES, D. D. et al. Avaliação da maciez da carne bovina. *Ciência Animal Brasileira*, Goiânia, v. 6, n. 3, p. 135–149, 2005.
- AMIN, M. et al. Níveis de energia líquida e ractopamina na qualidade da carne suína. *Revista Brasileira de Saúde e Produção Animal*, v. 15, p. 484–492, 2014.
- ANGERAMI, C. N. Influência do genótipo, sexo e peso de abate na composição da carcaça e nas características de qualidade da carne suína. 2004. Tese (Doutorado) – Universidade de São Paulo, Piracicaba, 2004.
- BALAGE, J. M. Prediction of pork meat quality using Vis/NIR spectroscopy. *Meat Science*, p. 37–43, 2015. DOI: <https://doi.org/10.1016/j.meatsci.2015.04.018>.
- BARBIN, D. F. et al. Digital image analyses as an alternative tool for chicken quality evaluation. *Biosystems Engineering*, v. 144, p. 85–93, 2016. DOI: <https://doi.org/10.1016/j.biosystemseng.2016>.
- BARBON, S. et al. Machine learning applied to near infrared spectra for classification of chicken meat. *Journal of Spectroscopy*, v. 2018, p. 8949741, 2018. DOI: <https://doi.org/10.1155/2018/8949741>.
- BEJERHOLM, C. et al. Cooking of meat. In: DIKEMAN, M.; DEVINE, C. (ed.). *Encyclopedia of Meat Sciences*. London: Elsevier, 2014. p. 370–376.
- BENEVENUTO JÚNIOR, A. A. Avaliação de rendimento de carcaça e de qualidade da carne de suínos comerciais, nativos e cruzados. 2001. Disponível em: <https://www.locus.ufv.br/handle/123456789/8942>. Acesso em: 20 maio 2025.
- BERNARDES, L. A. H.; PRATA, L. F. Influência do pH na capacidade de retenção de água e na coloração da carne: efeitos acentuados em carne PSE. In: MOSTRA CIENTÍFICA FAMEZ, 10., 2001. Anais [...]. 2001.
- BHARGAVA, A.; BANSAL, A. Evaluation of mono and bi-colored apples using computer vision and multispectral imaging. *Multimedia Tools and Applications*, v. 79, p. 7857–7874, 2020.
- BOLES, J. A.; PEGG, R. B. Meat color. In: HUI, Y. H. (ed.). *Meat Science and Applications*.

Boca Raton: CRC Press, 2001. p. 71–87.

BONIN, M. N. Avaliação de características de desempenho e qualidade de carne em linhagens e touros representativos da raça Nelore utilizando ultrassonografia, análise de imagens e NIRS. Tese (Doutorado), 2012.

BOULIANNE, M.; KING, A. J. Meat color and biochemical characteristics of unacceptable dark-colored broiler chicken carcasses. *Journal of Food Science*, v. 63, p. 759–762, 1998.

BRIDI, A. M.; SILVA, C. A. Avaliação da carcaça. In: _____. *Avaliação da carne suína*. Londrina: Midiograf, 2009. p. 1–15. Disponível em: http://www.uel.br/grupopesquisa/gpac/pages/arquivos/Material%20para%20consulta/Bridi%20e%20Silva,%202009_%20Avalia%C3%A7%C3%A3o%20da%20carca%C3%A7a%20su%C3%ADna.pdf. Acesso em: 20 maio 2025.

CANDOGAN, K. et al. Authentication and quality assessment of meat products by Fourier-transform infrared spectroscopy (FTIR). *Food Engineering Reviews*, v. 13, n. 1, p. 66–91, 2021.

CARTÍN-ROJAS, A. Food fraud and adulteration: a challenge for veterinary services. *Revue Scientifique et Technique*, v. 36, p. 1015–1024, 2017.

CHEN, X. et al. Non destructive detection of meat quality based on multiple spectral dimension reduction methods by near infrared spectroscopy. *Foods*, v. 12, n. 2, p. 300, 2023. DOI: 10.3390/foods12020300.

CRUZ, B. C. C. et al. Avaliação da composição centesimal e das características físico-químicas da carne de ovinos. *PUBVET*, v. 10, p. 111–189, 2016.

DAVIS, G. W. et al. Relationships of quality indicators to palatability attributes of pork loins. *Journal of Animal Science*, v. 41, n. 5, p. 1305–1313, 1975.

DE MORAES, E. C. Fundamentos de sensoriamento remoto. [S. l.], 2002.

DE NADAI, B. M. et al. Predição do valor de cisalhamento e da gordura intramuscular em carne de bovinos Nelore utilizando espectroscopia Vis-NIR. *Meat Science*, 2020.

DU, M.; AHN, D. U. Effect of dietary conjugated linoleic acid on growth rate and meat quality of broilers. *Poultry Science*, v. 81, p. 428–433, 2002.

ELMASRY, G. et al. Near-infrared hyperspectral imaging for predicting colour, pH and tenderness of fresh beef. *Journal of Food Engineering*, v. 110, p. 127–140, 2012.

ESTELLES-LOPEZ, L. et al. An automated classification platform for machine learning regression models for meat spoilage prediction using multispectral imaging and metabolomics profiling. *Food Research International*, v. 99, p. 206–215, 2017.

FABRE, R. et al. Cooking method effect on Warner-Bratzler shear force of different beef muscles. *Meat Science*, v. 138, p. 10–14, 2018.

FAUSTMAN, C. et al. Myoglobin and lipid oxidation interactions: mechanistic bases and control. *Meat Science*, v. 86, p. 86–94, 2010.

FENG, C. H. et al. Hyperspectral imaging and multispectral imaging as novel techniques for detecting defects in raw and processed meat products. *Food Control*, v. 84, p. 165–176, 2018.

FERRARA, D. C. C. Características qualitativas da carne suína de estabelecimentos do município de Dracena-SP. 2021. Trabalho acadêmico – Universidade Estadual Paulista, 2021. Disponível em: <https://repositorio.unesp.br>. Acesso em: 20 maio 2025.

FIGUEIREDO, D. Conceitos básicos de sensoriamento remoto. São Paulo, 2005.

FLEMING, B. K. et al. Heme pigment levels in broilers chilled in ice slush and air. *Poultry Science*, v. 70, p. 2197–2200, 1991.

GIAMPIETRO GANECO, A. Características qualitativas da carne de frango de corte proveniente de diferentes sistemas de produção. 2016. Tese (Doutorado em Zootecnia) – Universidade Estadual Paulista, Jaboticabal, 2016. Disponível em: <http://hdl.handle.net/11449/134321>. Acesso em: 12 maio 2025.

GIROLAMI, A. et al. Meat color determination by computer vision system. *Meat Science*, 2013. DOI: <https://doi.org/10.1016/j.meatsci.2012.08.010>.

GONZÁLEZ-MARTÍN, I. et al. Applications of spectroscopy and chemometrics for food authentication and traceability. *Food Chemistry*, 2023.

HMOMO, S. et al. ExpDes.pt: pacote para análise de experimentos em delineamentos experimentais no software R. *R Core Team*, versão 4.1.0, 2022.

HODGSON, R. R. et al. Relationships between pork loin palatability traits and physical characteristics of cooked chops. *Journal of Animal Science*, v. 69, n. 12, p. 4858–4865, 1991.

HONIKEL, K. O. Reference methods for the assessment of physical characteristics of meat. *Meat Science*, v. 49, n. 4, p. 447–457, 1998.

HUFF-LONERGAN, E.; LONERGAN, S. M. Mechanisms of water-holding capacity of meat: the role of postmortem biochemical and structural changes. *Meat Science*, v. 71, p. 194–204, 2005.

HUGHES, J. M. et al. A structural approach to understanding the interactions between colour, water-holding capacity and tenderness. *Meat Science*, v. 98, n. 3, p. 520–532, 2014.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). Calendário de divulgações 2026. 2026. Disponível em: <https://agenciadenoticias.ibge.gov.br>. Acesso em: 12 maio 2026.

JEŽEK, F. et al. Cooking of meat: effect on texture, cooking loss and microbiological quality – a review. *Acta Veterinaria Brno*, v. 88, n. 4, p. 487–496, 2019.

JIA, W. et al. Electronic noses as a powerful tool to assess meat quality: a mini review. *Food Analytical Methods*, v. 11, n. 10, p. 2916–2924, 2018.

JOO, S. T. et al. Control of fresh meat quality through manipulation of muscle fiber characteristics. *Meat Science*, v. 95, n. 4, p. 828–836, 2013. DOI: [10.1016/j.meatsci.2013.04.044](https://doi.org/10.1016/j.meatsci.2013.04.044).

JUDGE, M. D. et al. *Principles of Meat Science*. 2. ed. Dubuque: Kendall/Hunt Publishing, 1989.

KHALED, A. Y. et al. Emerging non-destructive approaches for meat quality and safety evaluation: a review. *Comprehensive Reviews in Food Science and Food Safety*, v. 20, p. 3438–

3463, 2021. DOI: <https://doi.org/10.1111/1541-4337.12781>.

KOOHMARAIE, M. Biochemical factors regulating the toughening and tenderization processes of meat. *Meat Science*, v. 43, p. 193–201, 1996.

KOOHMARAIE, M.; GEESINK, 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.

LAWRIE, R. A.; LEDWARD, D. A. *Lawrie's Meat Science*. 7. ed. Cambridge: Woodhead Publishing, 2006.

LI, W. et al. Quantitative RNA-seq-based transcriptome analysis of meat color and flavor in broilers treated with eucalyptus leaf polyphenol extract. *Journal of Food Science*, v. 85, p. 1319–1327, 2020.

LINDAHL, G. et al. Contribution of pigment content, myoglobin forms and internal reflectance to the colour of pork loin and ham from pure breed pigs. *Meat Science*, v. 59, n. 2, p. 141–151, 2001.

LUO, X. et al. Non-destructive determination of beef freshness indicators using three-dimensional machine vision and machine learning. *Journal of Food Engineering*, v. 340, p. 111305, 2023. DOI: 10.1016/j.jfoodeng.2022.111305.

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

MARITANO, V. et al. Anti-counterfeiting and fraud mitigation solutions for high-value food products. *Journal of Food Protection*, p. 100251, 2024.

MATARNEH, S. K. et al. New insights in muscle biology that alter meat quality. *Annual Review of Animal Biosciences*, v. 9, p. 355–377, 2021. DOI: 10.1146/annurev-animal-021419-083902.

MIR, N. A. et al. Determinants of broiler chicken meat quality and factors affecting them: a review. *Journal of Food Science and Technology*, v. 54, n. 10, p. 2997–3009, 2017.

MOELLER, S. J. et al. Consumer perceptions of pork eating quality as affected by pork quality attributes and end-point cooked temperature. *Meat Science*, v. 84, n. 1, p. 14–22, 2010.

MONTE, A. L. S. et al. Qualidade da carne de caprinos e ovinos: uma revisão. *Revista Agropecuária Científica no Semiárido*, v. 8, p. 11–17, 2012.

NAUE, C. R. et al. Sensoriamento remoto como ferramenta aos estudos de doenças de plantas agrícolas: uma revisão. *Revista Brasileira de Geografia Física*, v. 3, n. 3, p. 190–195, 2011.

NAGANATHAN, G. K. et al. Partial least squares analysis of hyperspectral imaging data for beef tenderness prediction. *Journal of Food Engineering*, v. 145, p. 12–19, 2015.

NORMAN, J. L. et al. Pork loin color relative to sensory and instrumental tenderness and consumer acceptance. *Meat Science*, v. 65, n. 2, p. 927–933, 2003.

NPPC. *Pork Quality Targets*. Des Moines, 1998.

NRC. *Nutrient Requirements of Swine*. 10. ed. Washington: National Academy of Sciences,

1998.

OLIVO, R. et al. Fatores que influenciam na cor de filés de peito de frango. *Revista Nacional da Carne*, São Paulo, v. 25, n. 289, p. 44–49, 2001.

OURIQUE, J. M. R.; NICOLAIEWSKY, S. Características físico-químicas e organolépticas e suas relações na avaliação da qualidade da carne suína. *Revista da Sociedade Brasileira de Zootecnia*, v. 19, n. 2, p. 118–125, 1990.

PICARD, B.; GAGAOUA, M. Meta-proteomics for the discovery of protein biomarkers of beef tenderness: an overview of integrated studies. *Food Research International*, v. 127, p. 108739, 2020. DOI: <https://doi.org/10.1016/j.foodres.2019.108739>.

PICARD, B.; GAGAOUA, M. Muscle fiber properties in cattle and their relationships with meat qualities: an overview. *Journal of Agricultural and Food Chemistry*, v. 68, n. 22, p. 6021–6039, 2020. DOI: 10.1021/acs.jafc.0c02086.

POPOVA, T. Effect of probiotics in poultry for improving meat quality. *Current Opinion in Food Science*, v. 14, p. 72–77, 2017.

QIAO, J. et al. Prediction of drip-loss, pH, and color for pork using a hyperspectral imaging technique. *Meat Science*, v. 76, n. 1, p. 1–8, 2007. DOI: 10.1016/j.meatsci.2006.06.031.

RADY, A.; ADEDEJI, A. Assessment of different processed meats for adulterants using visible-near infrared spectroscopy. *Meat Science*, v. 136, p. 59–67, 2018. DOI: <https://doi.org/10.1016/j.meatsci.2017.10.014>.

RAMOS, E. M.; GOMIDE, L. A. M. *Avaliação da qualidade de carnes: fundamentos e metodologias*. Viçosa: UFV, 2007.

RAMOS, E. M.; GOMIDE, L. A. M. *Tecnologia de abate e tipificação de carcaças*. Viçosa: UFV, 2009.

RENDLE, R. C.; KEELEY, G. Chemistry in the meat industry. In: WANSBROUGH, H. (ed.). *Animal Products A – Meat*. 1998. Disponível em: <http://nzic.org.nz/ChemProcesses/animal/5A.pdf>. Acesso em: 12 abr. 2025.

ROHMAN, A. et al. Comprehensive review on FTIR spectroscopy coupled with chemometrics for analysis of fats and oils authentication in food products. *Molecules*, v. 25, n. 22, p. 5485, 2020.

ROPODI, A. I. et al. Rapid detection of frozen-thawed minced meat using multispectral imaging and Fourier transform infrared spectroscopy. *Meat Science*, v. 135, p. 142–147, 2018.

RUBENSAM, J. M.; FELÍCIO, P. E.; TERMIGNONI, C. Influência do genótipo *Bos indicus* na atividade de calpastatina e na textura da carne de novilhos abatidos no sul do Brasil. *Ciência e Tecnologia de Alimentos*, v. 18, n. 4, p. 405–409, 1998.

SALIM, A. P. A. A. et al. Effect of different feeding systems on color of longissimus muscle from *Bos* cattle: a systematic review and meta-analysis. *Meat Science*, v. 192, p. 108871, 2022. DOI: <https://doi.org/10.1016/j.meatsci.2022.108871>.

SANTANA, D. C. Fenotipagem de alta precisão de caracteres industriais de soja usando aprendizado de máquina e diferentes sensores espectrais. 2023. Tese (Doutorado em

Agronomia) – Universidade Estadual Paulista, Ilha Solteira, 2023.

SANTANA, D. C. Fenotipagem de alto rendimento usando espectroscopia VIS/NIR na classificação de genótipos de soja para rendimento de grãos e características industriais. *Spectrochimica Acta Part A*, v. 310, 2024. DOI: <https://doi.org/10.1016/j.saa.2024.123963>.

SAÑUDO, C. et al. The microbiology of DFD fresh meats: a review. *Meat Science*, v. 55, n. 2, p. 181–191, 2000.

SARCINELLI, M. F. et al. Processamento de carne bovina. Vitória: Universidade Federal do Espírito Santo, 2007. (Boletim Técnico, n. 00807).

SAVOIA, S. et al. Prediction of meat quality characteristics at the slaughterhouse using portable near infrared spectrometers. *Meat Science*, p. 108017, 2020. DOI: <https://doi.org/10.1016/j.meatsci.2019.108017>.

SILVA, L. H. et al. Castration age and growth, production, and meat quality of Nelore male cattle. *Animal Production Science*, v. 60, p. 725–731, 2020.

SILVA, N. V. S. et al. Características de carcaça e carne ovina: uma abordagem das variáveis metodológicas e fatores de influência. *Acta Veterinaria Brasilica*, v. 2, p. 103–110, 2008.

SIRIPATRAWAN, U. Hyperspectral imaging for rapid quality deterioration index evaluation of vacuum-packed dry-cured sausages. *Sensors and Actuators B: Chemical*, v. 254, p. 1025–1032, 2018.

SOUZA, S. C.; RIBEIRO, L. F. Aplicação do bem-estar animal e abate humanitário de bovinos para garantia da qualidade da carne. *Revista Gestão, Tecnologia e Ciências*, v. 10, n. 28, p. 1–24, 2021.

SPYRELLI, E. D. et al. Evaluation of chicken breast fillet spoilage using Fourier-transform infrared spectroscopy and multispectral image analysis. *Current Research in Food Science*, v. 4, p. 121–131, 2021.

SUMAN, S. P. et al. Myoglobin chemistry and meat color. *Annual Review of Food Science and Technology*, v. 4, p. 79–99, 2013.

SUN, X. et al. Prediction of beef tenderness using multispectral imaging texture and color features. *Meat Science*, v. 92, n. 4, p. 386–393, 2012. DOI: [10.1016/j.meatsci.2012.04.030](https://doi.org/10.1016/j.meatsci.2012.04.030).

TAHERI-GARAVAND, A. et al. An intelligent non-destructive approach for real-time evaluation of chicken meat freshness based on computer vision technology. *Procedia Computer Science*, v. 124, p. 728–735, 2019.

TAIT, L. et al. Unmanned aerial vehicles (UAVs) for monitoring macroalgal biodiversity: comparison of RGB and multispectral imaging sensors for biodiversity assessments. *Remote Sensing*, v. 11, n. 19, p. 2332, 2019.

TERRA, N. N. *Apontamentos de tecnologia de carnes*. São Leopoldo: Unisinos, 1998.

TOLDRÁ, F. The role of muscle enzymes in dry-cured meat products with different drying conditions. *Trends in Food Science and Technology*, v. 17, p. 164–168, 2006.

TOMASEVIC, I. et al. Recent advances in meat color research. *Current Opinion in Food Science*, v. 41, p. 81–87, 2021. DOI: <https://doi.org/10.1016/j.cofs.2021.02.012>.

VAN OECKEL, M. J. et al. Pork tenderness estimation by taste panel, Warner–Bratzler shear force and on-line methods. *Meat Science*, v. 53, n. 4, p. 259–267, 1999.

VARNAM, A.; SUTHERLAND, J. P. *Meat and Meat Products: Technology, Chemistry and Microbiology*. London: Springer, 1995.

VELÁSQUEZ, L. et al. A decision tree-based application for classifying beef marbling by hyperspectral imaging. *Meat Science*, p. 43–50, 2017. DOI: <https://doi.org/10.1016/j.meatsci.2017.06.002>.

WARNER, R. D.; KAUFFMAN, R. G.; GREASER, M. L. Muscle protein changes post mortem in relation to pork quality traits. *Meat Science*, v. 45, n. 3, p. 339–352, 1997.

WARRISS, P. D.; BROWN, S. N. The relationship between reflectance (EEL value) and colour (L*) in pork loins. *Animal Science*, v. 61, n. 1, p. 145–147, 1995.

WIDEMAN, N. et al. Factors affecting poultry meat colour and consumer preferences – a review. *World's Poultry Science Journal*, v. 72, n. 2, p. 353–366, 2016.

WOJNOWSKI, W. et al. Application of proton transfer reaction mass spectrometry (PTR-MS) and electronic nose for meat freshness and authenticity assessment. *Food Chemistry*, v. 368, 2022.

WU, S. et al. Understanding the development of color and color stability of dark cutting beef based on mitochondrial proteomics. *Meat Science*, v. 163, p. 108046, 2020. DOI: <https://doi.org/10.1016/j.meatsci.2020.108046>.

YANG, C. C. et al. Development of multispectral image processing algorithms for identification of healthy, septicemic and inflammatory process chickens. *Journal of Food Engineering*, v. 69, p. 225–234, 2005.

YANG, G. et al. Unmanned aerial vehicle remote sensing for field-based crop phenotyping: current status and perspectives. *Frontiers in Plant Science*, v. 8, p. 1111, 2017.

ZHANG, W. et al. Technological demands of meat processing – an Asian perspective. *Meat Science*, v. 132, p. 35–44, 2017.

CAPÍTULO 2 - Avaliação espectral e aprendizado de máquina na predição de parâmetros físico-químicos da carne bovina

Este capítulo seguiu as normas da revista *Meat Science*, publicada pela Elsevier

RESUMO

A avaliação da qualidade da carne bovina por métodos convencionais frequentemente envolve análises destrutivas, maior tempo de processamento e maior demanda de mão de obra. Nesse contexto, técnicas espectrais associadas a algoritmos de aprendizado de máquina têm sido investigadas como alternativas rápidas, não invasivas e eficientes para estimar atributos de qualidade da carne. O presente estudo teve por objetivo avaliar o potencial da espectroscopia VIS-NIR associada a algoritmos de aprendizado de máquina para prever atributos qualitativos e quantitativos da carne bovina. Amostras do músculo *Longissimus dorsi* foram submetidas a análises físico-químicas convencionais, incluindo pH, perda por cocção, maciez, índice de fragmentação miofibrilar (IFM) e parâmetros de cor luminosidade (L^* = 0 preto, 100 branco), a^* determina a intensidade de verde (-) ao vermelho (+), e b^* a intensidade do azul (-) ao amarelo (+) e o chroma e ângulo de tonalidade (h^*). Paralelamente, foram obtidas leituras espectrais utilizando espectrorradiômetro FieldSpec, cujos dados foram processados e utilizados na modelagem preditiva por meio dos algoritmos redes neurais artificiais (RNA), REPTree (DT), M5P, Random Forest (RF), máquina de vetores de suporte (SVM) e ZeroR como modelo controle. O desempenho dos modelos foi avaliado por meio do coeficiente de correlação (r) e do erro absoluto médio (MAE). De forma geral, os modelos supervisionados apresentaram desempenho superior ao modelo controle, com destaque para os algoritmos M5P e RF, que apresentaram melhor capacidade preditiva para diversas variáveis analisadas como: pH, cocção, maciez, IFM, metamioglobina (MMb), desoximioglobina (Mb+), oximioglobina (O2Mb), L^* , a^* , b^* , c^* e h^* . Os resultados indicam que a espectroscopia VIS-NIR associada ao aprendizado de máquina apresenta potencial para a estimativa de atributos de qualidade da carne bovina, podendo atuar como ferramenta complementar ou alternativa às metodologias convencionais. Além disso, a abordagem apresenta vantagens operacionais, como rapidez nas análises, ausência de reagentes químicos e possibilidade de aplicação não destrutiva, contribuindo para avanços tecnológicos no controle de qualidade da carne.

Palavras-chave: aprendizado de máquina; carne bovina; espectroscopia não destrutiva; espectroscopia VIS-NIR; qualidade da carne.

1. INTRODUÇÃO

A carne bovina, é amplamente consumida em todo o mundo, é rica em proteínas, ferro, zinco e vitamina B12, além de apresentar sabor agradável e versatilidade (Davis et al., 2022). Assim, a avaliação da qualidade da carne tornou-se de grande preocupação tanto para pesquisadores quanto para consumidores, no entanto, as técnicas microbiológicas e físico-químicas convencionais são eficientes, mas trabalhosas e, demoradas, e exigem pessoal qualificado, além disso, são destrutivas e aplicáveis apenas para controle offline (Xiong et al., 2023).

Em contrapartida, técnicas de detecção não destrutivas, constituem um campo em expansão baseado em física, eletrônica, ciência da computação e algoritmos de aprendizado de máquina. Essas técnicas são rápidas, repetíveis, consideradas ecologicamente corretas por eliminarem a necessidade de reagentes químicos, econômicas e adequadas para avaliação online. Elas têm sido amplamente utilizadas para controle da qualidade de alimentos como carne, frutas, óleo, peixe, vegetais e laticínios (Arsalane et al., 2024).

Numerosos estudos têm sido realizados com o objetivo de desenvolver métodos rápidos, não destrutivos e não invasivos, aplicáveis tanto na produção animal quanto na indústria da carne. Ao longo da última década, avanços significativos foram observados na avaliação quantitativa das características de carcaça e da carne, especialmente por meio do uso de técnicas de imagem e espectroscopia (Teixeira et al., 2019, Narsaiah et al., 2020), aliadas a ferramentas modernas de processamento e análise de imagens. Além disso, o desenvolvimento de novos algoritmos tem possibilitado a predição mais acurada e eficiente dos atributos de qualidade da carcaça e da carne em diferentes etapas da cadeia produtiva. Para diversas espécies animais, estudos recentes e abrangentes têm demonstrado o elevado potencial dessas abordagens para a avaliação objetiva da qualidade dos produtos cárneos (Ho et al., 2015; Jorgensen et al., 2015).

Esses estudos demonstraram que a técnica de dados hiperespectral pode ser uma ferramenta rápida, não destrutiva e eficiente para a avaliação da qualidade e segurança de produtos alimentícios. Dados hiperespectral combina informações espaciais e espectrais, permitindo obter assinaturas espectrais detalhadas dos materiais analisados e identificar características físico-químicas que não são perceptíveis visualmente (Saha & Manickavasagan, 2021; Jo et al., 2024). Na avaliação da carne bovina, essa tecnologia apresenta potencial para estimar atributos relacionados à composição química, coloração, teor de gordura, umidade e outros parâmetros de qualidade, associando dados espectrais a algoritmos de aprendizado de

máquina (Adithya, 2022; Jo et al., 2024).

Dessa forma, hipotetiza-se que a utilização de imagens hiperespectrais associadas a algoritmos de aprendizado de máquina seja capaz de predizer, de forma rápida e não destrutiva, parâmetros físico-químicos da carne bovina com elevada precisão. Assim, este estudo teve por objetivo avaliar o desempenho de algoritmos de aprendizado de máquina associados à espectroscopia VIS-NIR-SWIR na predição de atributos qualitativos e físico-químicos da carne bovina, incluindo pH, perda por cocção, maciez, índice de fragmentação miofibrilar, pigmentos musculares e parâmetros de cor.

2. MATERIAL E MÉTODOS

2.1 Local e procedimentos

O experimento foi conduzido na Universidade Estadual de Mato Grosso do Sul (UEMS), no Laboratório de Avaliação de Carcaça e Qualidade de Carnes (GEQUAC), onde foram realizadas as análises convencionais. As análises relacionadas à aplicação de técnicas de aprendizado de máquina ocorreram no Laboratório LASPEC, vinculado à Universidade Federal de Mato Grosso do Sul (UFMS).

As amostras de contrafilé bovino (*Longissimus dorsi*) foram provenientes de um frigorífico sob inspeção federal (SIF), seguindo o protocolo de abate humanitário exigidos pela legislação brasileira por meio das normas do Regulamento Técnico de Inspeção de Produtos de Origem Animal (RISPOA).

2.2 Análises quantitativas e qualitativas

Após o recebimento no laboratório, todas as amostras foram descongeladas em ambiente resfriado. Os cortes de contrafilé foram racionados transversalmente às fibras musculares vermelha (oxidativa), originando bifes com espessura padronizada de 2,54 cm. As amostras foram então distribuídas aleatoriamente para a condução das análises.

As análises físico-químicas convencionais (pH, coloração, perda por cocção, maciez e IFM) foram conduzidas na UEMS, utilizando 7 amostras. O pH foi determinado pelo peagâmetro digital da marca Mettler M1120x (Mettler – Toledo International Inc., Columbus, OH, EUA).

A determinação dos componentes da cor L^* , a^* e b^* , foram realizadas após a retirada das peças das embalagens, expostas as misturas dos gases atmosféricos por 30 minutos, para oxigenação da mioglobina (Abularach et al., 1998). Foram realizadas 3 leituras por amostras, 3 leituras na parte de cima da amostra, utilizando o sistema CIE $L^*a^*b^*$, iluminante D65, 10° graus para observador padrão, usando o equipamento Chroma Meter CR – 400 (Konica Minolta. Sensing Inc, Sakai, Japan) calibrado para um padrão branco, onde o L^* é o chroma associado à luminosidade ($L^* = 0$ preto, 100 branco), a^* determina a intensidade de verde (-) ao vermelho (+), e b^* a intensidade do azul (-) ao amarelo (+) (HOUBEN et al., 2000). Para o chroma e ângulo de tonalidade (h^*), as informações foram retiradas do próprio equipamento.

A perda por cocção (PPC) foi avaliada conforme metodologia proposta pela American Meat Science Association – AMSA (1978). As amostras, previamente limpas e pesadas, foram assadas em forno elétrico a 180 °C até atingirem temperatura interna de 71 °C, mensurada

com termômetro digital. Após o cozimento, os bifes foram novamente pesados, e a PPC foi expressa em percentual, considerando a diferença entre o peso inicial e final.

Em seguida, foi realizada a análise de força de cisalhamento (FC). Para isso, foram retiradas seis amostras cilíndricas de 1,27 cm de diâmetro de cada bife, com orientação paralela às fibras musculares, utilizando furadeira de bancada modelo Ferrari FG-13. As amostras foram então cisalhadas perpendicularmente às fibras, com uso de lâmina em V (ângulo de 60°, espessura de 1,016 mm), acoplada ao texturômetro Brookfield CT-3 Texture Analyzer (Brookfield®, EUA), com velocidade fixa de 3,3 mm/s.

Para as de índice de fragmentação miofibrilar (IFM), foram retiradas 1 pedaço de cada amostra com 1,0 cm de espessura. As amostras de IFM foram embaladas, identificadas e congeladas a temperatura de -15°C. Estas análises foram realizadas nos laboratórios da Universidade Estadual do Mato Grosso do Sul (UEMS) – Unidade Universitária de Aquidauana -MS.

Diante disso, a metodologia para a realização do IFM foi subdividida nas etapas de extração das miofibrilas e determinação do teor proteico. As soluções tampão (KCl, KH₂PO₄, K₂HPO₄, EDTA, MgCl₂ e NaN₃) e biureto (CuSO₄*5H₂O, NaKC₄H₄O₆*4H₂O e NaOH 10% - livre de carbonato) utilizadas no protocolo foram produzidas e armazenadas de acordo com as metodologias e recomendações descritas por Ramos e Gomide (2009).

Na extração das miofibrilas, as amostras foram preparadas a partir de 5g de carne e 50mL de tampão, trituradas por 60s com mixer. O conteúdo foi peneirado (18 *mesh*), transferido para tubo falcon de mL, e centrifugado a 4000 rpm por 15 minutos. O líquido sobrenadante foi descartado, o precipitado foi suspenso pela adição de 6,5 ml de tampão e centrifugado novamente nas mesmas condições. Em seguida, um novo descarte de sobrenadante foi realizado, e novamente o precipitado foi suspenso em 3,5 ml de tampão. Essa alíquota foi mantida sob refrigeração a 4°C durante o protocolo de determinação do teor proteico.

Para a determinação do teor proteico (mg/ml), uma curva padrão foi elaborada nas concentrações proteicas de 0 (branco), 1,0; 2,5; 5,0; 7,5 e 10,0 mg/ml, a partir da diluição de BSA 1% e solução tampão, e 4ml biureto. Em seguida, as amostras foram preparadas pela homogeneização de 0,25ml de alíquota e 4,7 ml de solução de biureto em tubos falcons, protegidos da luminosidade. Os tubos foram agitados no vórtex por 30s e mantidos em local escuro por 30min. Posteriormente, as reações foram lidas no espectrofotômetro (Bioespectro, modelo SP-220) a 540nm em cubeta de vidro. Um fator de diluição de 3,8 foi utilizado no cálculo do teor proteico de cada amostra.

Com a concentração proteica de cada amostra, as alíquotas foram diluídas com a solução

tampão, diretamente na cubeta de vidro, para obter 1mg/ml de proteína, e lidas imediatamente no espectrofotômetro a 540 nm. A absorção foi multiplicada por uma constante de 300 para gerar o índice de fragmentação miofibrilática.

2.3 Análise espectral

Durante as análises qualitativas, previamente à realização da análise de perda por cocção (PPC), foi retirada de cada uma das sete amostras uma porção com dimensões aproximadas de 2 cm × 2 cm. Essas porções foram submetidas às análises espectrais no Laboratório de Espectroscopia (LASPEC/UFMS), utilizando o equipamento ocean optics.

Foram realizadas cinco leituras em pontos distintos de cada porção, totalizando 35 leituras, utilizando ocean optics constituído de dois sensores: STS-VIS e o Flame dos quais abrangem um intervalo espectral de 350 a 2200 nm. A calibração do equipamento foi realizada em uma placa branca que reflete 100% da luz, feita com sulfato de bário. Esse sensor estava conectado a um computador para os registros de cada leitura por meio de um software OceanView, que é responsável pelas leituras processadas pelo equipamento.

Após a coleta, os dados espectrais foram processados no software ViewSpecPro, utilizado para geração das curvas espectrais e conversão dos arquivos para o formato .txt, facilitando a organização e o processamento das informações. Posteriormente, os dados foram tabulados para aplicação das análises de aprendizado de máquina. As leituras espectrais obtidas das amostras de carne foram utilizadas como variáveis de entrada nos modelos de aprendizado de máquina. Cada amostra foi analisada cinco vezes, sendo que cada leitura gerou aproximadamente 2200 informações espectrais relacionadas ao comportamento da reflectância da carne ao longo dos comprimentos de onda avaliados.

2.4 Aprendizado de máquina

Os espectros gerados foram utilizados como entrada dos algoritmos, enquanto as variáveis físico-químicas e de qualidade da carne foram utilizadas como variáveis de saída dos modelos preditivos.

Os algoritmos foram desenvolvidos para identificar padrões entre o comportamento espectral da reflectância e as características da carne. Para a construção dos modelos, o banco de dados foi automaticamente dividido em conjuntos de treinamento (80%) e teste (20%), permitindo o treinamento dos algoritmos e a posterior avaliação de sua capacidade preditiva.

A predição dos clusters foi realizada utilizando validação cruzada estratificada do tipo k-fold com $k = 10$ e 10 repetições, totalizando 100 execuções por modelo, com o objetivo de aumentar a robustez e a estabilidade das estimativas de desempenho. Todos

os algoritmos foram executados com os parâmetros padrão do software WEKA versão 3.8.5 (Bouckaert et al., 2010), exceto as Redes Neurais Artificiais, nas quais foi utilizada uma arquitetura com duas camadas ocultas compostas por 10 neurônios em cada camada, definida com o objetivo de equilibrar capacidade de aprendizado e generalização do modelo.

Foram utilizados os seguintes algoritmos: redes neurais artificiais (RNA), REPTree (DT), árvore de decisão (M5P), floresta aleatória (RF), máquina de vetores de suporte (SVM) e ZeroR que foi utilizada como modelo de controle, sendo algoritmo padrão do weka. O Weka é um software de código aberto que reúne diversos algoritmos de aprendizado de máquina para tarefas com dados de classificação, regressão, clustering, mineração de regras de associação e visualização.

2.5 Análise estatística

Para avaliar a precisão das predições dos algoritmos, foram estimadas as métricas de acurácia coeficiente de correlação (R) e Erro Absoluto Médio (MAE), que expressam, respectivamente, a associação entre valores observados e preditos e a magnitude média do erro de predição.

O coeficiente de correlação (R) foi calculado conforme a Equação 1:

$$R = \frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2}}$$

Em que:

- O_i = valor observado;
- P_i = valor predito;
- $\bar{O}$ = média dos valores observados;
- $\bar{P}$ = média dos valores preditos;
- n = número de observações.

O Erro Absoluto Médio (MAE) foi obtido de acordo com a Equação 2:

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - P_i|$$

Em que:

- O_i = valor observado;
- P_i = valor predito;
- n = número total de observações.

Em seguida, foi realizada a análise de variância, adotando-se o delineamento inteiramente casualizado (DIC) para os valores preditos. Para o agrupamento das médias das métricas R e MAE, foi utilizado o teste de Scott-Knott a 5% de probabilidade. Todas as análises estatísticas foram conduzidas no software Rbio versão 162 (Bhering, 2017) e nos pacotes ExpDes.pt e ggplot2 do software R versão 4.1.0 (Ohmomo et al., 2022).

3. RESULTADOS

A aplicação da espectroscopia associada a algoritmos de aprendizado de máquina demonstrou capacidade variável de predição para os atributos qualitativos e quantitativos da carne bovina (Figuras 1 a 12). Sendo assim, os modelos supervisionados apresentaram desempenho superior ao modelo controle (ZeroR), destacando entre os dados espectrais e as variáveis avaliadas.

De maneira geral, observou-se predominância de modelos baseados em árvores de decisão (M5P), além do bom desempenho de modelos como Random Forest (RF).

Para a variável pH (Figura 1), é possível observar que os algoritmos RF e M5P apresentaram os maiores coeficientes de correlação de Pearson (r) (0,5) e os menores valores de erro absoluto médio (MAE), diferenciando estatisticamente dos demais modelos ($p < 0,05$). O modelo ZeroR apresentou o menor desempenho, com baixa correlação e elevado erro, confirmando sua limitação como modelo de controle. Para a perda de cocção (Figura 2), o modelo M5P apresentou simultaneamente maior r e menor MAE, caracterizando-se como o melhor algoritmo para essa variável.

Na predição de maciez (Figura 3) destacaram-se DT (REPTree) e M5P, apresentando a maior correlação e menor erro. A presença dos dois modelos baseados em árvores entre os melhores sugere que a variável maciez pode ser bem representada por estruturas de particionamento do espaço. Árvores de decisão possuem a capacidade de identificar pontos de corte e interações específicas entre variáveis, o que pode explicar o bom desempenho observado.

Na predição do IFM (Figura 4), destacou-se o M5P apresentando melhor correlação e menor erro. Esse resultado pode mostrar que a fragmentação miofibrilar apresenta padrões espectrais que podem ser segmentadas eficientemente por estruturas de árvore, especialmente quando há regiões do espectro associadas a alterações estruturais específicas.

As variáveis %MMb (Metamioglobina), %Mb (Mioglobina) e %O₂Mb (oxiomioglobina) representam os pigmentos da carne (Figuras 5, 6 e 7). Para %MMb², o modelo RF apresentou melhor desempenho.

Para %Mb⁺, os modelos RF e DT apresentaram melhor desempenho. Já para %O₂Mb, o modelo que se destacou foi o RF, apresentando maiores valores de r e o menor MAE. Esse comportamento reforça o uso dos modelos baseados em árvores nas variáveis com forte base espectral.

Nos parâmetros de cor, para L* (Figuras 8) destacaram-se M5P e RF. A forte

associação entre reflectância espectral e luminosidade pode favorecer tanto modelos lineares locais (M5P) quanto modelos ensemble (RF). Para a variável a^* (Figuras 9), o modelo M5P apresentou melhor desempenho.

Para o parâmetro b^* (Figuras 10), os modelos M5P e RF apresentaram maiores valores de r e apresentaram menor MAE. Já para o parâmetro C^* (Figura 11), apenas o modelo M5P apresentou melhor desempenho. E para h^* , os modelos M5P, RF apresentaram maiores valores de r e menor MAE.

De forma geral, verificou-se a predominância do modelo M5P, seguido pelo RF, evidenciando que algoritmos baseados em árvores, apresentam maior capacidade de adaptação aos padrões espectrais, resultando em melhor desempenho preditivo.

4. DISCUSSÃO

A interpretação dos modelos obtidos neste estudo deve inicialmente considerar o comportamento espectral observado nas curvas médias VIS-NIR das amostras. As curvas evidenciaram diferenças de absorção ao longo das regiões do visível e do infravermelho próximo, refletindo variações nos constituintes químicos e estruturais da carne bovina. Na região do visível (aproximadamente 350–2200 nm), observaram-se alterações associadas principalmente aos pigmentos de mioglobina, responsáveis pela coloração da carne, enquanto no infravermelho próximo destacaram-se bandas relacionadas às vibrações moleculares de ligações O–H, C–H e N–H, associadas à água, lipídios e proteínas (Prieto et al., 2014; Fodor et al., 2024).

Essas respostas espectrais fornecem suporte físico-químico para o desempenho dos modelos preditivos observados neste trabalho. Regiões espectrais associadas à água e às proteínas miofibrilares apresentam relação direta com características estruturais da carne, influenciando atributos como maciez e capacidade de retenção de água. Da mesma forma, bandas relacionadas aos pigmentos heme ajudam a explicar o comportamento das variáveis instrumentais de cor.

Os resultados obtidos neste estudo reforçam o potencial da espectroscopia VIS-NIR como ferramenta não destrutiva para predição da maciez da carne bovina, assim como de outras variáveis de qualidade, corroborando evidências apresentadas em estudos anteriores que demonstram a viabilidade da aplicação de técnicas espectrais associadas a métodos de modelagem para avaliação rápida da qualidade da carne.

Essas características explicam por que variáveis relacionadas à cor e pigmentos apresentaram desempenho consistente com modelos baseados em árvores e ensembles (RF). A presença de bandas específicas relacionadas à oximioglobina e metamioglobina favorece algoritmos preparados para explorar interações não lineares e múltiplas regiões espectrais simultaneamente.

Considerando os resultados obtidos, é possível observar que a espectroscopia associada a algoritmos de aprendizado de máquina apresenta desempenho consistente na predição de atributos físico-químicos e qualitativos da carne bovina. No entanto, o comportamento dos modelos mudou conforme a natureza biológica da variável, sugerindo que a relação entre espectro e propriedade da carne não é uniforme, mas dependente da complexidade estrutural e bioquímica do atributo avaliado.

As variáveis estruturais como maciez e IFM não possuem assinatura espectral

direta, ou seja, ela depende de interpretação visual de texturas e não apenas dos valores da reflectância, que são captadas indiretamente por alterações na estrutura proteica e no estado da água intramuscular. Essa natureza indireta pode justificar a necessidade de modelos capazes de segmentar o espaço espectral (DT e M5P), permitindo capturar padrões locais associados a mudanças estruturais.

O bom desempenho observado para modelos baseados em árvores, principalmente M5P e Random Forest (RF), está em concordância com estudos que evidenciam a eficiência desses algoritmos na análise de dados espectrais aplicados à avaliação da qualidade de alimentos e carne bovina. Trabalhos anteriores demonstraram que métodos de ensemble e árvores de decisão apresentam elevada capacidade de modelar relações não lineares e interações complexas entre comprimentos de onda espectrais e atributos físico-químicos da carne (Cozzolino & Murray, 2004; Prieto et al., 2009; Ripoll et al., 2018).

Segundo Prieto et al. (2009), técnicas quimiométricas associadas à espectroscopia NIR apresentam elevada eficiência na predição de atributos de qualidade da carne, especialmente quando os modelos conseguem explorar múltiplas regiões espectrais simultaneamente. Da mesma forma, Ripoll et al. (2018) destacaram que algoritmos baseados em aprendizado de máquina, incluindo Random Forest, apresentam desempenho robusto para classificação e predição de características relacionadas à composição e qualidade da carne bovina devido à sua capacidade de lidar com dados espectrais complexos e altamente correlacionados.

Além disso, Fodor et al. (2024) ressaltam que métodos de machine learning vêm apresentando vantagens sobre modelos lineares tradicionais em aplicações envolvendo espectroscopia VIS-NIR, especialmente em situações nas quais há elevada variabilidade biológica e relações não lineares entre espectro e variável resposta.

Estudos demonstraram que modelos de RF apresentam desempenho robusto na predição de atributos de qualidade da carne a partir de dados espectrais e hiperespectrais, incluindo parâmetros de cor, composição química e características estruturais (Kamruzzaman et al., 2012; Naganathan et al., 2015).

Kamruzzaman et al. (2012), avaliando carne de cordeiro da raça Charollais, utilizaram três músculos do *semitendinosus* (ST), *Longissimus dorsi* (LD) e o músculo *Psoas maior* (PM) usando a espectroscopia no infravermelho próximo associada a modelos de aprendizado de máquina, os resultados mostraram que a imagem hiperespectral NIR, tem um grande potencial como ferramenta não destrutiva para a discriminação de músculos. Esse estudo corrobora com o presente trabalho, uma vez que

foi avaliado o *Longissimus dorsi* de bovinos, ainda assim as variáveis apresentaram resultados semelhantes, concluindo que é possível utilizar o método de aprendizado de máquina.

No presente estudo, a predição da maciez da carne bovina a partir de dados espectrais obtidos pelo FieldSpec apresentou melhor desempenho para os modelos DT e M5P, que apresentaram os menores valores de MAE entre os algoritmos avaliados. Esse resultado sugere que a relação entre as informações espectrais e a maciez da carne pode apresentar comportamento não linear ou dependente de regiões específicas do espectro, favorecendo algoritmos baseados em particionamento do espaço de dados, como árvores de decisão e modelos de regressão local.

Resultados semelhantes têm sido relatados em estudos mais recentes envolvendo espectroscopia VIS-NIR associada a técnicas de aprendizado de máquina para avaliação da qualidade da carne bovina. Fodor et al. (2024) destacaram que modelos de machine learning aplicados a dados espectrais apresentam elevado potencial para predição de atributos físico-químicos e sensoriais da carne, incluindo maciez, devido à capacidade de explorar relações não lineares entre os comprimentos de onda e as características estruturais do músculo. Os autores ressaltam ainda que regiões espectrais associadas à água, proteínas e lipídios possuem forte relação com alterações bioquímicas decorrentes do processo de maturação da carne.

Esses achados corroboram os resultados obtidos no presente estudo, no qual os modelos desenvolvidos a partir dos espectros coletados pelo espectrorradiômetro apresentaram desempenho satisfatório para variáveis relacionadas à maciez. Dessa forma, os resultados reforçam o potencial da espectroscopia VIS-NIR como ferramenta rápida e não destrutiva para avaliação da qualidade da carne bovina, especialmente em atributos ligados à estrutura muscular e às propriedades texturais.

Estudos envolvendo espectroscopia VIS-NIR e aprendizado de máquina também têm demonstrado resultados promissores para predição simultânea de atributos de qualidade da carne bovina, como maciez, pH e cor. Fodor et al. (2024) destacaram que as informações espectrais obtidas na região do visível e infravermelho próximo estão diretamente relacionadas a alterações estruturais e bioquímicas do músculo, especialmente aquelas associadas às proteínas miofibrilares, ao estado da água intramuscular e aos pigmentos responsáveis pela coloração da carne. Segundo os autores, a integração entre dados espectrais e algoritmos de machine learning permite elevada capacidade preditiva para variáveis físico-químicas e sensoriais da carne.

Os resultados observados no presente estudo corroboram essas evidências, uma vez que os modelos desenvolvidos apresentaram desempenho satisfatório para variáveis relacionadas à maciez, pH e cor. Esses achados reforçam o potencial da espectroscopia VIS-NIR associada a técnicas de modelagem como alternativa rápida, não destrutiva e com potencial de aplicação prática em substituição parcial aos métodos convencionais de avaliação da qualidade da carne bovina.

Estudos adicionais também demonstram o potencial da espectroscopia NIR para estimar maciez. Prieto et al. (2014) destacam que a interação da radiação no infravermelho próximo com ligações moleculares presentes na carne, especialmente relacionadas à água e proteínas, pode fornecer informações indiretas sobre a estrutura do tecido muscular e, conseqüentemente, sobre a maciez da carne. No presente estudo, os melhores resultados para pH foram os modelos M5P e RF.

A identificação de DT e M5P como os melhores modelos pode indicar que os dados espectrais obtidos pelo FieldSpec apresentam padrões locais que são bem capturados por algoritmos baseados em árvores. Além disso, esses modelos possuem a capacidade de identificar limiares e relações condicionais entre variáveis, o que pode ser particularmente útil para variáveis complexas como a maciez, cuja variabilidade é influenciada por fatores estruturais, bioquímicos e fisiológicos do músculo (Lepetit, 2008).

Em relação aos pigmentos e parâmetros de cor o melhor desempenho observado foi para RF na predição de pigmentos (%MMb, %Mb⁺ e MAE de %O₂Mb), isso pode ser explicado pela forte relação entre espectro visível e as diferentes formas da mioglobina. As formas químicas da mioglobina apresentam bandas de absorção características no espectro visível, particularmente associadas às regiões de absorção da oximioglobina e metamioglobina (Faustman & Cassens, 1990). Essa relação direta entre composição pigmentária e reflectância espectral facilita a modelagem preditiva.

No presente estudo, M5P e RF também apresentaram bons resultados para L*, b* e h*, enquanto M5P destacou-se para a* e C*. Esses resultados indicam que a modelagem baseada em regressões lineares locais pode capturar adequadamente variações espectrais associadas à intensidade e tonalidade da cor.

Além do desempenho estatístico, a utilização de espectroscopia VIS-NIR associada a aprendizado de máquina apresenta vantagens operacionais relevantes quando comparada às metodologias tradicionais de avaliação da qualidade da carne.

O tempo de análise por amostra pode diminuir para poucos tempo, permitindo

potencial aplicação em sistemas automatizados de classificação e controle de qualidade. Ademais, a redução da necessidade de mão de obra laboratorial representa também grandes vantagens para sistemas de produção que demandam alta eficiência operacional.

Entretanto, algumas limitações devem ser consideradas, principalmente o reduzido número amostral e a utilização de apenas um músculo bovino, o que pode limitar a generalização dos modelos.

Dessa forma, estudos futuros devem incluir maior número de amostras, diferentes músculos e categorias animais, além da aplicação de técnicas mais avançadas de processamento espectral e inteligência artificial, visando ampliar a robustez e a aplicação industrial dos modelos preditivos.

5. CONCLUSÃO

A espectroscopia VIS-NIR associada a algoritmos de aprendizado de máquina demonstrou potencial para a predição de atributos qualitativos da carne bovina. Entre os modelos avaliados, M5P e RF apresentaram melhor desempenho, indicando que algoritmos baseados em árvores e regressões locais possuem maior capacidade de capturar os padrões presentes nos dados espectrais. Os resultados obtidos evidenciam que variáveis como pH, cocção, maciez, IFM, pigmentos e parâmetros de cor podem ser estimados por meio de informações espectrais com desempenho promissor ou bem desenvolvido.

REFERÊNCIAS

- ABULARACH, M. L. S. et al. Características de qualidade do contrafilé (m. Longissimus dorsi) de touros jovens da raça Nelore. *Ciência e Tecnologia de Alimentos*, v. 18, n. 2, p. 205–210, 1998. DOI: 10.1590/S0101-20611998000200012.
- ADITHYA, S. C. A review of hyperspectral imaging in the quality evaluation of meat, fish, poultry and their products. *Meat Technology*, v. 63, n. 2, p. 109–120, 2022.
- AMERICAN MEAT SCIENCE ASSOCIATION (AMSA). Guidelines for cookery and sensory evaluation of meat. Chicago: American Meat Science Association, National Livestock and Meat Board, 1978.
- ARSALANE, A. et al. Application of mechatronic systems in food quality assessment. *International Journal of Electrical and Computer Engineering*, v. 14, n. 5, p. 5858–5865, 2024. DOI: 10.11591/ijece.v14i5.pp5858-5865.
- BHERING, L. L. Rbio: A tool for biometric and statistical analysis using the R platform. *Crop Breeding and Applied Biotechnology*, v. 17, n. 2, p. 187–190, 2017.
- BOUCKAERT, R. R. et al. WEKA—Experiences with a Java open-source project. *Journal of Machine Learning Research*, v. 11, p. 2533–2541, 2010.
- COZZOLINO, D.; MURRAY, I. Identification of animal meat muscles by visible and near infrared reflectance spectroscopy. *LWT - Food Science and Technology*, v. 37, n. 4, p. 447–452, 2004.
- DAVIS, H.; MAGISTRALI, A.; BUTLER, G.; STERGIADIS, S. Nutritional benefits of fatty acids in organic and grass-fed beef. *Foods*, v. 11, n. 5, p. 646, 2022. DOI: 10.3390/foods11050646.
- ELMASRY, G. et al. Near-infrared hyperspectral imaging for predicting colour, pH and tenderness of fresh beef. *Journal of Food Engineering*, v. 110, n. 1, p. 127–140, 2012.
- FAUSTMAN, C.; CASSENS, R. G. The biochemical basis for discoloration in fresh meat. *Journal of Muscle Foods*, v. 1, n. 3, p. 217–243, 1990.
- FODOR, M. et al. Advances in near-infrared spectroscopy for food quality evaluation. *Foods*, v. 13, n. 21, p. 3501, 2024.
- HO, H. et al. Generic software modules for the meat industry. In: MALTIN, C.; CRAIGIE, C.; BÜNGER, L. (eds.). *FAIM Farm Animal Imaging — A Summary Report*. Edinburgh: SRUC, 2015. p. 109–112.
- HOUBEN, J. H. et al. Effect of dietary vitamin E supplementation, fat level and packaging on colour stability and lipid oxidation in minced beef. *Meat Science*, v. 54, n. 1, p. 17–22, 2000.
- JO, K. et al. Hyperspectral imaging–based assessment of fresh meat quality: Progress and applications. *Microchemical Journal*, v. 197, p. 109785, 2024. DOI: 10.1016/j.microc.2023.109785.

- KAMRUZZAMAN, M. et al. Application of NIR hyperspectral imaging for discrimination of lamb muscles. *Food Chemistry*, v. 134, n. 4, p. 2184–2191, 2012.
- LEPETIT, J. Collagen contribution to meat toughness. *Meat Science*, v. 80, n. 4, p. 960–967, 2008.
- NAGANATHAN, G. K. et al. Partial least squares analysis of hyperspectral imaging data for beef tenderness prediction. *Journal of Food Engineering*, v. 145, p. 12–19, 2015.
- NARSAIAH, K. et al. Non-destructive methods for carcass and meat quality evaluation. In: BISWAS, A. K.; MANDAL, P. K. (eds.). *Meat Quality Analysis*. Cambridge: Academic Press, 2020. p. 37–49.
- OHMOMO, H. et al. Advances in molecular and analytical methods for food authentication and detection of adulteration in meat products. *Food Control*, v. 133, p. 108588, 2022.
- PRIETO, N. et al. Application of near infrared reflectance spectroscopy to predict meat and meat products quality. *Meat Science*, v. 83, n. 2, p. 175–186, 2009.
- PRIETO, N. et al. Online application of visible and near infrared reflectance spectroscopy to predict chemical-physical and sensory characteristics of beef quality. *Meat Science*, v. 97, n. 3, p. 393–404, 2014.
- RAMOS, E. M.; GOMIDE, L. A. M. *Avaliação da qualidade de carnes: fundamentos e metodologias*. Viçosa: Editora UFV, 2019.
- RIPOLL, G. et al. Instrumental meat quality parameters and prediction of tenderness using visible and near-infrared spectroscopy in beef. *Meat Science*, v. 145, p. 308–314, 2018.
- SAHA, D.; MANICKAVASAGAN, A. Machine learning techniques for analysis of hyperspectral images to determine quality of food products: A review. *Current Research in Food Science*, v. 4, p. 28–44, 2021. DOI: 10.1016/j.crfs.2021.01.002.
- TEIXEIRA, A. et al. Advances in sheep and goat meat products research. In: TOLDRA, F. (ed.). *Advances in Food and Nutrition Research*. Cambridge: Academic Press, v. 87, p. 305–370, 2019.
- XIONG, Y. et al. Non-destructive detection of chicken freshness based on electronic nose technology and transfer learning. *Agriculture*, v. 13, n. 2, p. 496, 2023. DOI: 10.3390/agriculture13020496.

FIGURAS




Figura 1. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de pH. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 2. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de cocção. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%





Figura 3. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de maciez. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%





Figura 4. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de IFM. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 5. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %MMb. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 6. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %Mb+. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 7. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %O2Mb. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 8. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de L*. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%





Figura 9. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de a^* . Letras iguais não diferem entre si pelo teste de Scott Knott a 5%





Figura 10. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de b^* . Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 11. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de C^* . Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 12. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de h^* . Letras iguais não diferem entre si pelo teste de Scott Knott a 5%

CAPÍTULO 3 – Predição de atributos qualitativos da carne de frango e suíno a partir de dados espectrais utilizando aprendizado de máquina

Este capítulo seguiu as normas da revista *Meat Science*, publicada pela Elsevier

RESUMO

A carne suína e a carne de frango são importantes fontes de proteína de alta qualidade e nutrientes essenciais. Este estudo avaliou o potencial da espectroscopia associada à aprendizagem de máquina na predição de parâmetros de qualidade da carne de frango e suína. Amostras de peito de frango (fibra glicolítica) e lombo suíno (fibra oxidativa-glicolítica) foram analisadas por métodos convencionais e dados espectrais. Foram avaliados pH, perda por cocção, maciez, índice de fragmentação miofibrilar (IFM), pigmentos metamioglobina (%MMb), desoximioglobina (%Mb+) e oximioglobina (%O2Mb) e parâmetros de cor L^* é o croma associado à luminosidade ($L^* = 0$ preto, 100 branco), a^* determina a intensidade de verde (-) ao vermelho (+), e b^* a intensidade do azul (-) ao amarelo (+) e o chroma e ângulo de tonalidade (h^*). Os algoritmos utilizados incluíram redes neurais artificiais, árvores de decisão (DT), M5P, Random Forest (RF), máquinas de vetores de suporte (SVM) e ZeroR. O desempenho dos modelos variou conforme a variável e o tipo de fibra muscular. O modelo DT apresentou melhor desempenho para pH em ambas as fibras, enquanto o M5P se destacou para maciez e IFM. Para perda por cocção, o DT foi superior em frango, enquanto M5P, RF e SVM apresentaram bom desempenho em suínos. O RF predominou na predição dos pigmentos, enquanto o M5P foi superior para variáveis de cor. A integração entre espectroscopia e aprendizagem de máquina mostrou-se promissora como método rápido, não destrutivo e aplicável na avaliação da qualidade da carne.

Palavras-chave: Aprendizagem de máquina, Frango; Hiperespectral; Qualidade da carne; Suíno;

1. INTRODUÇÃO

A carne suína constitui uma importante fonte de proteína de alto valor biológico, além de fornecer nutrientes essenciais, desempenhando papel relevante nos sistemas alimentares e na economia de diversas culturas (Font-IFurnols & Guerrero, 2014; Pearson et al., 2024). As abordagens tradicionais para prever os parâmetros de qualidade de carne suína tem se baseado principalmente em métodos estatísticos, como análise de regressão (Caballero et al., 2017).

No entanto, apesar dos avanços obtidos com técnicas espectrais aplicadas à avaliação da qualidade da carne, ainda existem limitações relacionadas ao desempenho preditivo e à aplicabilidade prática dos modelos, especialmente diante da elevada variabilidade biológica dos produtos cárneos. Estudos recentes destacam que atributos como pH, cor, textura e capacidade de retenção de água apresentam comportamento altamente complexo e dependente de múltiplos fatores físico-químicos, dificultando a construção de modelos universalmente robustos (Jo et al., 2024; Fodor et al., 2024).

Nesse contexto, carnes de frango e suíno, assim como a carne bovina, apresentam elevada variabilidade em características de qualidade ao longo da cadeia produtiva, exigindo métodos rápidos, não destrutivos e eficientes para monitoramento contínuo. Segundo Jo et al. (2024), embora a espectroscopia VIS-NIR e as imagens hiperespectrais apresentem elevado potencial para aplicações industriais, desafios relacionados à heterogeneidade das amostras, interferências espectrais e generalização dos modelos ainda limitam parcialmente sua aplicação em larga escala.

Estudos mais recentes também demonstram avanços significativos na aplicação de imagens hiperespectrais para predição de atributos de qualidade em carnes. Jo et al. (2024) relataram que técnicas hiperespectrais associadas a métodos de aprendizado de máquina apresentaram elevada eficiência na estimativa de variáveis como pH, cor, perda por gotejamento e textura em produtos cárneos, superando, em diversos casos, o desempenho de métodos convencionais destrutivos. Segundo os autores, a combinação entre informações espectrais e algoritmos capazes de modelar relações complexas possibilita maior precisão e rapidez na avaliação da qualidade da carne ao longo da cadeia produtiva.

Nesse cenário, a aplicação de espectroscopia associada à aprendizado de máquina tem se destacado como uma abordagem inovadora, permitindo a modelagem de dados complexos e a predição de parâmetros físico-químicos com elevada acurácia. Trabalhos

como os de Barbon et al. (2018) e Savoia et al. (2020) evidenciam que algoritmos de aprendizado supervisionado são capazes de capturar relações não lineares entre os espectros e as características da carne, contribuindo para o avanço de sistemas automatizados de avaliação de qualidade.

Assim, a tecnologia de dados hiperespectral tem se provado ser uma ferramenta inovadora para analisar com precisão os espectros de materiais heterogêneos com variações espaciais em suas propriedades físicas e bioquímicas (Brondum et al., 2000; Xiong et al., 2014).

Dessa forma, hipotetiza-se que a utilização de imagens hiperespectrais associadas a algoritmos de aprendizado de máquina seja capaz de prever, de forma rápida e não destrutiva, parâmetros físico-químicos da carne suína e de frango com elevada precisão.

Com isso, este estudo teve por objetivo avaliar o desempenho de diferentes algoritmos de aprendizado de máquina associados à espectroscopia VIS-NIR na predição de atributos qualitativos da carne suína e de frango, incluindo pH, perda por cocção, maciez, índice de fragmentação miofibrilar, pigmentos musculares e parâmetros de cor, considerando as diferenças metabólicas entre fibras glicolíticas e oxidativa-glicolíticas.

2. MATERIAL E MÉTODOS

2.1 Local e procedimentos

O experimento foi conduzido na Universidade Estadual de Mato Grosso do Sul (UEMS), no Laboratório de Avaliação de Carcaça e Qualidade de Carnes (GEQUAC), onde foram realizadas as análises convencionais. As análises relacionadas à aplicação de técnicas de aprendizado de máquina foram conduzidas no Laboratório LASPEC, vinculado à Universidade Federal de Mato Grosso do Sul (UFMS).

As amostras de lombo suíno (*Longissimus dorsi*) e peito de frango (*Pectoralis major*) foram obtidas de um frigorífico sob Serviço de Inspeção Federal (SIF), seguindo os protocolos de abate humanitário estabelecidos pela legislação brasileira, conforme o Regulamento de Inspeção Industrial e Sanitária de Produtos de Origem Animal (RIISPOA).

Devido às diferenças metabólicas e estruturais entre os músculos avaliados, esperam-se distintos comportamentos espectrais entre as carnes suína e de frango, especialmente em função das variações na composição química, teor de água, pigmentos musculares e características das fibras musculares. Essas diferenças podem influenciar diretamente a resposta espectral e, conseqüentemente, o desempenho dos modelos preditivos aplicados aos atributos de qualidade da carne.

2.2 Análises quantitativas e qualitativas

Após o recebimento no laboratório, todas as amostras foram descongeladas sob refrigeração e posteriormente higienizadas. Os cortes de lombo suíno foram seccionados transversalmente às fibras musculares intermediárias (oxidativas-glicolíticas), obtendo-se bifes com espessura padronizada de 2,54 cm. Os filés de peito de frango também foram padronizados com espessura de 2,54 cm, necessitando apenas de limpeza superficial. Em seguida, as amostras foram distribuídas aleatoriamente para realização das análises.

As análises físico-químicas convencionais (pH, coloração, perda por cocção, maciez e IFM) foram conduzidas na UEMS, utilizando sete amostras por tipo de fibra (suínos e aves), totalizando 14 análises primárias.

O pH foi determinado utilizando peagâmetro digital Mettler M1120x (Mettler – Toledo International Inc., Columbus, OH, EUA), sendo realizadas três leituras por amostra.

A avaliação da cor (L^* , a^* e b^*) foi realizada após a retirada das peças das embalagens e exposição ao ar atmosférico por 30 minutos para oxigenação da mioglobina

(Abularach et al., 1998). Foram feitas três leituras por amostra na superfície dos bifes, utilizando o sistema CIE *Lab**, iluminante D65 e observador padrão de 10°, com o equipamento Chroma Meter CR-400 (Konica Minolta Sensing Inc., Sakai, Japan), calibrado em padrão branco. O parâmetro L^* representa a luminosidade, a^* varia do verde (-) ao vermelho (+) e b^* do azul (-) ao amarelo (+) (Houben et al., 2000). Os valores de chroma e ângulo de tonalidade (h^*) foram obtidos diretamente pelo equipamento.

A perda por cocção (PPC) foi determinada conforme metodologia da American Meat Science Association – AMSA (1978). As amostras foram limpas, pesadas e assadas em forno elétrico a 180 °C até atingirem temperatura interna de 71 °C, monitorada com termômetro digital. Após o cozimento, as amostras foram novamente pesadas, sendo a PPC expressa em percentual pela diferença entre os pesos inicial e final.

Na análise de força de cisalhamento (FC), foram retiradas seis amostras cilíndricas de 1,27 cm de diâmetro de cada bife, paralelas às fibras musculares, utilizando furadeira de bancada Ferrari FG-13. As amostras foram cisalhadas perpendicularmente às fibras com lâmina em V (60° e espessura de 1,016 mm) acoplada ao texturômetro Brookfield CT-3 Texture Analyzer (Brookfield®, EUA), operando à velocidade de 3,3 mm/s.

Para análise do índice de fragmentação miofibrilar (IFM), foi retirado um fragmento de 1,0 cm de espessura de cada amostra. As amostras foram embaladas a vácuo, armazenadas entre 1 e 2 °C em câmara climática por 24 horas e posteriormente congeladas a -15 °C. As análises foram realizadas nos laboratórios da Universidade Estadual de Mato Grosso do Sul (UEMS), Unidade Universitária de Aquidauana-MS.

A metodologia do IFM foi dividida em extração das miofibrilas e determinação do teor proteico. As soluções tampão e de biureto utilizadas foram preparadas conforme Ramos e Gomide (2009).

Na extração das miofibrilas, utilizaram-se 5 g de carne e 50 mL de tampão, homogeneizados por 60 segundos em mixer com lâminas cegas. O material foi peneirado, centrifugado a 4000 rpm por 15 minutos e o sobrenadante descartado. O precipitado foi ressuspenso em tampão e centrifugado novamente nas mesmas condições. Após nova lavagem, o precipitado foi mantido sob refrigeração a 4 °C até a determinação do teor proteico.

Para determinação do teor proteico (mg/mL), foi elaborada uma curva padrão nas concentrações de 0; 1,0; 2,5; 5,0; 7,5 e 10,0 mg/mL utilizando BSA 1%, solução tampão e biureto. As amostras foram preparadas com 0,25 mL da alíquota e 4,7 mL de solução de biureto, protegidas da luz, agitadas em vórtex por 30 segundos e mantidas em repouso

por 30 minutos. Posteriormente, as leituras foram realizadas em espectrofotômetro (Bioespectro SP-220) a 540 nm. Foi aplicado fator de diluição de 3,8 no cálculo do teor proteico.

Com a concentração proteica determinada, as alíquotas foram diluídas em solução tampão até atingir 1 mg/mL de proteína e imediatamente analisadas em espectrofotômetro a 540 nm. A absorbância obtida foi multiplicada pela constante 300 para obtenção do índice de fragmentação miofibrilar.

2.3 Análise espectral

Durante as análises qualitativas, antes de ser realizada a análise de cocção (PPC), foi retirado um pedaço das 7 amostras de cada tipo de fibra, cada uma com o tamanho aproximadamente de 2 cm por 2 cm, onde foram utilizadas análises espectrais no Laboratório LASPEC (UFMS), utilizando o equipamento FieldSpec. Para cada uma das 7 amostras por tipo de fibra, foram realizadas 5 leituras espectrais por repetição, resultando em 35 leituras por grupo aves (glicolítica) suíno (oxidativa-glicolítica).

As porções foram encaminhadas ao laboratório LASPEC/UFMS para aquisição dos dados espectrais. Foram realizadas cinco leituras em pontos distintos de cada porção, totalizando 35 leituras, utilizando ocean optics constituído de dois sensores: STS-VIS e o Flame dos quais abrangem um intervalo espectral de 350 a 2200 nm. A calibração do equipamento foi realizada uma placa branca que reflete 100% da luz, feita com sulfato de bário. Esse sensor estava conectado a um computador para os registros de cada leitura por meio de um software OceanView, que é responsável pelas leituras processadas pelo equipamento.

Após a obtenção dos dados espectrais foi construída uma curva para cada tipo de fibra, processando os dados em programa próprio do sensor chamado ViewSpecPro, que permite a conversão dos arquivos em extensão txt facilitando a análise e processamento. Posteriormente os dados foram tabulados para análises com ML.

2.4 Aprendizado de máquina

Os espectros gerados foram utilizados como entrada dos algoritmos, enquanto as variáveis físico-químicas e de qualidade da carne foram utilizadas como variáveis de saída dos modelos preditivos.

Os algoritmos foram desenvolvidos para identificar padrões entre o comportamento espectral da reflectância e as características da carne. Para a construção

dos modelos, o banco de dados foi automaticamente dividido em conjuntos de treinamento (80%) e teste (20%), permitindo o treinamento dos algoritmos e a posterior avaliação de sua capacidade preditiva.

A predição dos clusters foi realizada por validação cruzada estratificada do tipo k-fold, com $k = 10$ e 10 repetições, totalizando 100 execuções por modelo, com o objetivo de aumentar a robustez e estabilidade das estimativas. Todos os algoritmos foram executados com os parâmetros padrão do software WEKA versão 3.8.5 (Bouckaert et al., 2010), exceto as Redes Neurais Artificiais, que utilizaram duas camadas ocultas com 10 neurônios cada, visando equilibrar capacidade de aprendizado e generalização do modelo.

Foram utilizados os algoritmos Redes Neurais Artificiais (RNA), REPTree (DT), árvore de decisão (M5P), Floresta Aleatória (RF), Máquina de Vetores de Suporte (SVM) e ZeroR, utilizado como modelo de controle por ser o algoritmo padrão do WEKA. O WEKA é um software de código aberto que reúne diversos algoritmos de aprendizado de máquina para tarefas de classificação, regressão, clustering, mineração de regras de associação e visualização de dados.

2.5 Análises estatísticas

Para avaliar a precisão das predições dos algoritmos, foram estimadas as métricas de acurácia coeficiente de correlação (R) e Erro Absoluto Médio (MAE), que representam, respectivamente, a associação entre valores observados e preditos e a média dos erros de predição.

O coeficiente de correlação (R) foi calculado conforme a Equação 1:

$$R = \frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2}}$$

Em que:

- O_i = valor observado;
- P_i = valor predito;
- $\bar{O}$ = média dos valores observados;
- $\bar{P}$ = média dos valores preditos;
- n = número de observações.

O Erro Absoluto Médio (MAE) foi obtido de acordo com a Equação 2:

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - P_i|$$

Em que:

- O_i = valor observado;
- P_i = valor predito;
- n = número total de observações.

Posteriormente, foi realizada a análise de variância, adotando-se o delineamento inteiramente casualizado (DIC) para os valores preditos. Para o agrupamento das médias das métricas R e MAE, foi realizado pelo teste de Scott-Knott a 5% de probabilidade. Todas as análises estatísticas foram conduzidas no software Rbio versão 162 (Bhering, 2017) e nos pacotes ExpDes.pt e ggplot2 do software R versão 4.1.0 (Ohmomo et al., 2022)

3. RESULTADOS

Para a variável de pH foi possível observar que os modelos DT se apresentou melhor para fibra glicolítica e os modelos DT, M5P, RF e SVM se apresentaram melhor para a fibra oxidativa-glicolítica (figura 13 e figura 25).

Ja para a variável de cocção o modelo M5P correspondeu melhor para ambas as fibras, no entanto para a fibra oxidativa-glicolítica os demais modelos RF e SVM também corresponderam para esta variável (figura 14 e figura 26). Na predição da maciez, o modelo M5P apresentou melhor desempenho tanto para a fibra glicolítica e oxidativa-glicolítica.

O modelo M5P apresentou melhor desempenho na variável de IFM para a fibra glicolítica, enquanto para a oxidativa-glicolítica os modelos DT, M5P e RF apresentaram melhores resultados.

Em relação aos pigmentos da carne, o parâmetro de %MMb o modelo RF apresentou melhor desempenho para ambas as fibras (figura 17) e (figura 29). Na variável de %Mb+, o modelo RF apresentou melhor desempenho tanto na fibra glicolítica (figura 18) quanto para a oxidativa-glicolítica (figura 30). Para %O2Mb, o modelo RF apresentou melhor desempenho na fibra glicolítica (figura 19) enquanto na fibra oxidativa-glicolítica os modelos RF e SVM apresentaram melhores resultados.

De maneira geral, observa-se a predominância do modelo RF na predição dos pigmentos da carne, apresentando melhor desempenho na maioria das condições avaliadas, notadamente para a fibra glicolítica. Esse resultado mostra a maior capacidade desse algoritmo modelar relações complexas entre os dados espectrais e os estados da mioglobina. Além disso, a consistência do desempenho do RF em diferentes tipos de fibra indicar maior robustez frente à variabilidade biológica do tecido muscular.

Nos parâmetros de cor, especificamente luminosidade (L^*), o modelo M5P apresentou melhor desempenho tanto para a fibra glicolítica (figura 20) e oxidativa-glicolítica (figura 32). Para intensidade de vermelho (a^*), o modelo RF apresentou melhor desempenho para a fibra glicolítica (figura 21), enquanto na oxidativa-glicolítica os modelos DT e M5P apresentaram melhor desempenho (figura 33). Para intensidade de amarelo (b^*), os modelos DT, M5P e RF apresentaram melhor desempenho para a fibra glicolítica (figura 23), enquanto na oxidativa - glicolítica os modelos DT e M5P foram superiores. Em chroma (C^*), os modelos DT, M5P e RF apresentaram melhor desempenho na fibra glicolítica (figura 23), enquanto oxidativa-glicolítica os modelos DT e M5P foram mais eficientes (figura 35). No ângulo de tonalidade (h^*), o modelo M5P apresentou melhor desempenho em ambas as fibras, indicando elevada capacidade desse algoritmo em modelar

variações espectrais associadas à tonalidade da carne.

Com tudo, é possível observar a predominância do modelo M5P na predição das váriveis de cor, indicando maior capacidade desse algoritmo em descrever as relações entre os dados espectrais e os parâmetros colorimétricos da carne. Esse comportamento pode ser atribuído à natureza mais contínua e estruturada das variáveis de cor (L^* , a^* , b^* , C^* e h^*), que apresentam relações mais lineares com as informações espectrais, favorecendo o uso de modelos baseados em regressões locais.

4. DISCUSSÃO

Os modelos de aprendizado de máquina apresentaram desempenhos distintos na predição dos parâmetros de qualidade da carne de frango (fibra glicolítica) e suína (fibra oxidativa-glicolítica) a partir dos dados espectrais, destacando que diferentes algoritmos possuem capacidades variadas para capturar relações entre os sinais espectrais e as propriedades físico-químicas da carne. Entretanto, cabe frisar que ambas as fibras musculares (aves e suíno), apresentam características distintas.

Considerando os resultados obtidos, observa-se que algoritmos baseados em árvores de decisão e métodos ensemble apresentaram maior capacidade de modelar as relações não lineares entre os espectros de reflectância e os atributos de qualidade da carne, corroborando resultados reportados na literatura para aplicações espectrais em produtos cárneos (ElMasry et al., 2012).

Quando comparados aos métodos convencionais de avaliação da qualidade da carne, os métodos baseados em espectroscopia e aprendizado de máquina apresentam diversas vantagens. Tradicionalmente, parâmetros como pH, maciez, perda por cocção, cor e fragmentação miofibrilar são determinados por meio de análises laboratoriais que exigem preparo de amostras, utilização de equipamentos específicos e, em muitos casos, destruição parcial do material analisado (Ramos e Gomide, 2007; Passeti et al., 2023). Além disso, esses procedimentos geralmente demandam maior tempo de processamento, mão de obra especializada e etapas adicionais de limpeza e calibração dos equipamentos.

Foi possível observar que em algumas variáveis, alguns modelos se desenvolveram melhor para uma fibra do que para outra, esse comportamento pode ser explicado pelas diferenças metabólicas entre as espécies e tipos de fibras musculares. Em aves, a predominância de fibras glicolíticas, caracterizadas por metabolismo anaeróbio intenso e maior variação na queda do pH post-mortem, pode gerar padrões espectrais mais distintos, facilitando a segmentação e modelagem pelos algoritmos. Em contrapartida, em suínos, a presença predominante de fibras oxidativa-glicolíticas resulta em maior estabilidade metabólica e menor variabilidade nos valores de pH, o que pode dificultar a diferenciação dos padrões espectrais e impactar o desempenho preditivo (Joo et al., 2013).

Além disso, o destaque do modelo DT pode ser atribuído à sua capacidade de segmentar os dados em regiões específicas, capturando padrões distintos relacionados às condições musculares e metabólicas. Dessa forma, os resultados indicam que a eficiência dos modelos de aprendizado de máquina na predição do pH está diretamente relacionada à variabilidade dos dados, sendo favorecida em condições de maior heterogeneidade, como observado em aves, e mais limitada em cenários de

maior homogeneidade, como nos suínos.

Na perda por cocção (PPC), observou-se melhor desempenho do modelo M5P em geral, para ambas as fibras, o que pode ser explicado pela relação da capacidade de retenção de água com o pH, a estrutura das proteínas e a integridade das fibras musculares. Sendo assim, A PPC apresenta comportamento relativamente contínuo, sendo influenciada por fatores estruturais e bioquímicos que afetam a retenção de água durante o aquecimento (AMSA, 1978). Assim, modelos baseados em regressão local apresentam maior eficiência na sua predição.

No caso da maciez, avaliada por força de cisalhamento e o índice de fragmentação miofibrilar (IFM), o modelo M5P também demonstrou boa capacidade de predição para ambas as fibras, indicando que essas variáveis possuem relação intermediária entre linearidade e complexidade. A maciez está diretamente relacionada às alterações estruturais do músculo durante o período *pós-mortem*, enquanto o IFM reflete o grau de fragmentação dessas estruturas, sendo ambos fortemente influenciados pela atividade enzimática e pela organização estrutural das fibras musculares (Ramos & Gomide, 2009; Joo et al., 2013). Dessa forma, modelos que conseguem aplicar regressões locais (como M5P) tendem a apresentar melhor ajuste.

Além dos parâmetros estruturais e tecnológicos, os modelos também apresentaram boa capacidade de predição dos pigmentos musculares, incluindo metamioglobina (%MMb), desoximioglobina (%Mb) e oximioglobina (%O2Mb). O modelo RF se apresentou melhor para essas variáveis, especialmente para a fibra glicolítica, enquanto na fibra oxidativa-glicolítica outros modelos também apresentaram desempenho competitivo.

Nesse contexto, modelos baseados em ensemble, como o RF, apresentam maior capacidade de capturar essas interações complexas, uma vez que combinam múltiplas árvores de decisão, reduzindo a variância e aumentando a robustez preditiva.

Esses pigmentos são responsáveis pela coloração da carne e estão diretamente relacionados aos estados redox da mioglobina. Alterações nesses estados químicos influenciam diretamente a absorção e reflectância da luz na carne, afetando sua aparência e estabilidade de cor (Mancini & Hunt, 2005; Faustman et al., 2010). Como consequência, as técnicas espectrais demonstram elevada sensibilidade para detectar essas variações químicas no tecido muscular.

A predominância do RF observada neste estudo pode estar relacionada à sua capacidade de lidar com grande volume de variáveis espectrais e ruídos inerentes às medições, proporcionando maior estabilidade em comparação a modelos individuais, como árvores de decisão simples. Esses achados reforçam o potencial do uso de algoritmos de aprendizado de máquina, especialmente baseados em ensemble, como ferramentas eficazes na predição de pigmentos da carne, contribuindo para o avanço de métodos rápidos e não destrutivos de avaliação da qualidade.

Em relação aos parâmetros colorimétricos (L , a , b^* , C^* e h^*), foi possível observar a superioridade do modelo M5P para ambas as fibras, glicolítica e oxidativa-glicolítica. A cor, expressa pelos valores L^* , a^* e b^* está diretamente associada à absorção e refletância da luz na superfície muscular, sendo fortemente influenciada pelos estados químicos da mioglobina e pela estrutura do tecido (MacDougall, 1994). Dessa forma, as variações espectrais na região do visível apresentam comportamento mais contínuo e, em muitos casos, linear ou localmente linear.

Nesse contexto, o modelo M5P, por combinar árvores de decisão com regressões lineares nas folhas, apresenta maior capacidade de ajustar essas relações, capturando tanto padrões globais quanto variações locais dos dados. Segundo ElMasry et al. (2012), técnicas espectrais associadas a modelos quimiométricos e de regressão apresentam elevado desempenho na predição de atributos de cor em produtos cárneos, justamente pela alta correlação entre as respostas espectrais e os parâmetros colorimétricos. Além disso, Naganathan et al. (2015) destacam que modelos capazes de explorar relações estruturadas e contínuas tendem a apresentar melhor desempenho para variáveis diretamente ligadas à refletância da carne.

Dessa forma, os resultados obtidos reforçam o potencial da espectroscopia associada ao aprendizado de máquina como ferramenta inovadora para avaliação da qualidade da carne, oferecendo uma alternativa mais rápida, eficiente e não destrutiva em comparação aos métodos convencionais. Embora a substituição completa das técnicas laboratoriais ainda dependa de estudos adicionais de validação, os resultados indicam que essas abordagens apresentam grande potencial para complementar ou substituir gradualmente os métodos tradicionais em sistemas de controle de qualidade da indústria de carnes.

Como destaque, o estudo demonstrou o potencial da espectroscopia VIS-NIR associada ao aprendizado de máquina na predição rápida e não destrutiva de atributos qualitativos da carne. Entretanto, limitações relacionadas ao número reduzido de amostras e à variabilidade biológica entre fibras musculares podem influenciar o desempenho dos modelos. Assim, estudos futuros devem avaliar um maior número de amostras, diferentes condições de processamento e armazenamento, além da aplicação de novos algoritmos e técnicas de pré-processamento espectral, visando aumentar a robustez e a aplicabilidade industrial dos modelos preditivos.

5. CONCLUSÃO

Os resultados demonstraram que a espectroscopia VIS-NIR associada a algoritmos de aprendizado de máquina apresenta potencial para a predição rápida e não destrutiva de atributos qualitativos da carne suína e de frango. O desempenho dos modelos variou conforme a variável analisada e o tipo de fibra muscular, sendo observadas maiores capacidades preditivas para atributos relacionados à cor e ao pH em músculos com predominância de fibras glicolíticas, enquanto músculos oxidativo-glicolíticos apresentaram respostas espectrais distintas devido às diferenças na composição de mioglobina, teor de água e metabolismo energético. Essas diferenças estruturais e bioquímicas influenciaram diretamente os padrões de absorção espectral, evidenciando a sensibilidade da espectroscopia VIS-NIR às características fisiológicas dos diferentes tipos musculares.

Entre os algoritmos avaliados, destacaram-se o Random Forest na predição dos pigmentos musculares e o M5P para parâmetros de cor, maciez, perda por cocção e índice de fragmentação miofibrilar. Dessa forma, a integração entre espectroscopia VIS-NIR e aprendizado de máquina demonstra potencial como ferramenta inovadora para avaliação da qualidade da carne e futura aplicação em sistemas automatizados da indústria cárnea.

REFERÊNCIAS

ABULARACH, M. L. S. et al. Características de qualidade do contrafilé (*Longissimus dorsi*) de touros jovens da raça Nelore. *Ciência e Tecnologia de Alimentos*, v. 18, n. 2, p. 205–210, 1998. <https://doi.org/10.1590/S0101-20611998000200012>.

AMERICAN MEAT SCIENCE ASSOCIATION (AMSA). Guidelines for cookery and sensory evaluation of meat. Chicago: National Livestock and Meat Board, 1978.

BARBON, S. et al. Near infrared spectroscopy and machine learning applied to chicken meat classification. *Spectroscopy Letters*, v. 51, n. 8, p. 381–391, 2018. <https://doi.org/10.1080/00387010.2018.1504163>.

BHERING, L. L. Rbio: A tool for biometric and statistical analysis using the R platform. *Crop Breeding and Applied Biotechnology*, v. 17, n. 2, p. 187–190, 2017. <https://doi.org/10.1590/1984-70332017v17n2s29>.

BOUCKAERT, R. R. et al. WEKA—Experiences with a Java open-source project. *Journal of Machine Learning Research*, v. 11, p. 2533–2541, 2010.

BRONDUM, J. et al. Pork quality classification using near infrared spectroscopy. *Meat Science*, v. 55, n. 2, p. 177–185, 2000. [https://doi.org/10.1016/S0309-1740\(99\)00141-2](https://doi.org/10.1016/S0309-1740(99)00141-2).

CABALLERO, D. et al. Prediction of pork meat quality using fractals and data mining techniques on MRI images. *Food Research International*, v. 99, p. 739–747, 2017. <https://doi.org/10.1016/j.foodres.2017.06.048>.

ELMASRY, G. et al. Hyperspectral imaging for nondestructive determination of some quality attributes for strawberry. *Journal of Food Engineering*, v. 81, n. 1, p. 98–107, 2007. <https://doi.org/10.1016/j.jfoodeng.2006.10.016>.

ELMASRY, G. et al. Near-infrared hyperspectral imaging for predicting colour, pH and tenderness of fresh beef. *Journal of Food Engineering*, v. 110, n. 1, p. 127–140, 2012. <https://doi.org/10.1016/j.jfoodeng.2011.11.028>.

FAUSTMAN, C. et al. Myoglobin and lipid oxidation interactions: Mechanistic bases and control. *Meat Science*, v. 86, n. 1, p. 86–94, 2010. <https://doi.org/10.1016/j.meatsci.2010.04.025>.

FONT-I-FURNOLS, M.; GUERRERO, L. Consumer preference, behaviour and perception about meat and meat products: An overview. *Meat Science*, v. 98, n. 3, p. 361–371, 2014. <https://doi.org/10.1016/j.meatsci.2014.06.025>.

HOUBEN, J. H. et al. Effect of dietary vitamin E supplementation, fat level and packaging on colour stability and lipid oxidation in minced beef. *Meat Science*, v. 55, n. 3, p. 331–336, 2000. [https://doi.org/10.1016/S0309-1740\(99\)00161-8](https://doi.org/10.1016/S0309-1740(99)00161-8).

JOO, S. T. et al. Control of fresh meat quality through manipulation of muscle fiber characteristics. *Meat Science*, v. 95, n. 4, p. 828–836, 2013. <https://doi.org/10.1016/j.meatsci.2013.04.044>.

LIU, Y. et al. Prediction of colour, texture and sensory characteristics of beef steaks by visible and near infrared reflectance spectroscopy: A feasibility study. *Meat Science*, v. 65, n. 3, p. 1107–1115, 2003. [https://doi.org/10.1016/S0309-1740\(02\)00328-5](https://doi.org/10.1016/S0309-1740(02)00328-5).

MACDOUGALL, D. B. Colour of meat. In: PEARSON, A. M.; DUTSON, T. R. (eds.). *Quality attributes and their measurement in meat, poultry and fish products*. New York: Springer, 1994. p. 79–93.

MANCINI, R. A.; HUNT, M. C. Current research in meat color. *Meat Science*, v. 71, n. 1, p. 100–121, 2005. <https://doi.org/10.1016/j.meatsci.2005.03.003>.

OHMOMO, H. et al. Advances in molecular and analytical methods for food authentication and detection of adulteration in meat products. *Food Analytical Methods*, v. 15, p. 2143–2161, 2022. <https://doi.org/10.1007/s12161-022-02262-6>.

PASSETI, A. et al. Parâmetros de qualidade avaliados em carne bovina: uma revisão. *Brazilian Journal of Animal and Environmental Research*, v. 6, n. 2, p. 1319–1332, 2023. <https://doi.org/10.34188/bjaerv6n2-012>.

PEARSON, A. J. et al. Opportunities and challenges for global food security in advancing circular policies and practices in agrifood systems. *npj Science of Food*, v. 8, n. 1, 2024. <https://doi.org/10.1038/s41538-024-00286-7>.

QIAO, J. et al. Prediction of drip-loss, pH, and color for pork using a hyperspectral imaging technique. *Meat Science*, v. 76, n. 1, p. 1–8, 2007. <https://doi.org/10.1016/j.meatsci.2006.06.031>.
RAMOS, E. M.; GOMIDE, L. A. M. *Avaliação da qualidade de carnes: fundamentos e metodologias*. Viçosa: UFV, 2007.

SAVOIA, S. et al. Prediction of meat quality traits at slaughterhouse level using portable and hand-held near-infrared spectrometers. *Meat Science*, v. 161, 108017, 2020. <https://doi.org/10.1016/j.meatsci.2019.108017>.

VIHINEN, M. How to evaluate performance of prediction methods? Measures and their interpretation in variation effect analysis. *BMC Genomics*, v. 13, suppl. 4, S2, 2012. <https://doi.org/10.1186/1471-2164-13-S4-S2>.

XIONG, Y. L. Protein oxidation and implications for muscle food quality. *Meat Science*, v. 98, n. 3, p. 255–262, 2014. <https://doi.org/10.1016/j.meatsci.2014.02.007>.

FIGURAS




Figura 13. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de pH para frango. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 14. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de cocção para frango. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 15. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de maciez para frango. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 16. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de IFM para frango. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 17. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %MMb para frango. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 18. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %Mb+ para frango. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 19. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %O2Mb para frango. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 20. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de L* para frango. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 21. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de a^* para frango. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 22. . Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de b^* para frango. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 23. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de C^* para frango. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 24. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de h^* para frango. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 25. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de pH para suíno. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 26. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de cocção para suíno. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 27. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de maciez para suíno. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 28. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de IFM para suíno. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 29. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %MMb para suíno. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 30. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %Mb+ para suíno. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 31. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de %O2Mb para suíno. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 32. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de L* para suíno. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 33. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de a^* para suíno. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 34. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de b^* para suíno. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 35. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de C^* para suíno. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%




Figura 36. Correlação de Pearson (r) e erro absoluto médio (MAE) na predição de h^* para suíno. Letras iguais não diferem entre si pelo teste de Scott Knott a 5%

CAPÍTULO 5 – NOTA TÉCNICA

Este capítulo apresenta uma nota técnica elaborada com o objetivo de traduzir os resultados da pesquisa para aplicação prática no campo. A redação seguiu integralmente as orientações editoriais da Revista do Conselho Federal de Medicina Veterinária (CFMV).

APRENDIZADO DE MÁQUINAS NA CLASSIFICAÇÃO E AVALIAÇÃO DE DIFERENTES TIPOS DE FIBRAS MUSCULARES ATRAVÉS DA ESPECTRORADIOMETRIA

¹Universidade Estadual de Mato Grosso do Sul (UEMS), Unidade Universitária de Aquidauana, 79200-000, MS, Brasil

Da teoria à prática: Como os atributos de qualidade (cor, maciez) influenciam a decisão de compra do consumidor no dia a dia?

A cor é o primeiro atributo avaliado no momento da compra, sendo associada à frescura a qualidade. Já a maciez é percebida no consumo e determina a satisfação do consumidor. Carnes com boa aparência (cor), macias tendem a gerar maior aceitação e recompra, enquanto produtos com textura dura ou aspecto visual indesejável são rejeitados.

Quais são as principais diferenças entre as carnes bovina, suína e de frango em relação às fibras musculares e à composição nutricional, e como isso influencia suas características de qualidade e consumo?

As carnes bovina, suína e de frango apresentam diferenças marcantes tanto na composição das fibras musculares quanto no perfil nutricional, o que influencia diretamente suas características de qualidade e a preferência do consumidor.

A carne bovina possui maior predominância de fibras oxidativas (tipo I), ricas em mioglobina, o que confere coloração vermelho-escura e sabor mais intenso. Do ponto de vista nutricional, destaca-se pelo alto teor de proteínas de alto valor biológico, ferro heme (de alta biodisponibilidade), zinco e vitaminas do complexo B, especialmente B12. Em geral, apresenta maior teor de gordura, dependendo do corte, o que contribui para sabor e suculência, mas também pode influenciar na escolha por consumidores que buscam dietas mais magras.

A carne suína apresenta composição intermediária de fibras musculares, com equilíbrio entre fibras oxidativas e glicolíticas, resultando em coloração rosada e boa maciez. Nutricionalmente, também é rica em proteínas de alta qualidade, vitaminas do complexo B (com destaque para tiamina)

e minerais como ferro e zinco. Atualmente, muitos cortes suínos apresentam teor de gordura reduzido, tornando-se uma opção mais equilibrada entre sabor e valor nutricional.

Já a carne de frango, especialmente o peito, possui predominância de fibras glicolíticas, com menor teor de mioglobina, resultando em coloração clara. É reconhecida pelo baixo teor de gordura, principalmente quando sem pele, além de alto teor proteico e boa digestibilidade. Também fornece vitaminas do complexo B, como niacina (B3), e minerais, embora em menor concentração de ferro em comparação à carne bovina.

Na prática, essas diferenças explicam o perfil de consumo: a carne bovina é valorizada pelo sabor e valor nutricional (especialmente ferro), a suína pelo equilíbrio entre sabor e maciez, e a de frango pela leveza, menor teor de gordura e também na questão econômica por apresentar valores menores as vezes que as demais carnes e na praticidade e agilidade de fazer as receitas. Assim, a escolha do consumidor envolve não apenas características sensoriais, mas também aspectos nutricionais, saúde e econômica.

De que forma tecnologias como aprendizado de máquina podem contribuir, indiretamente, para melhorar a experiência do consumidor com a carne?

O aprendizado de máquina permite prever e padronizar atributos de qualidade, reduzindo a variabilidade dos produtos. Isso garante carnes com características mais consistentes, melhorando a confiança do consumidor e sua satisfação, mesmo sem que ele perceba diretamente o uso da tecnologia.

Quais benefícios o consumidor pode ter com a adoção de métodos rápidos e não destrutivos na avaliação da qualidade da carne?

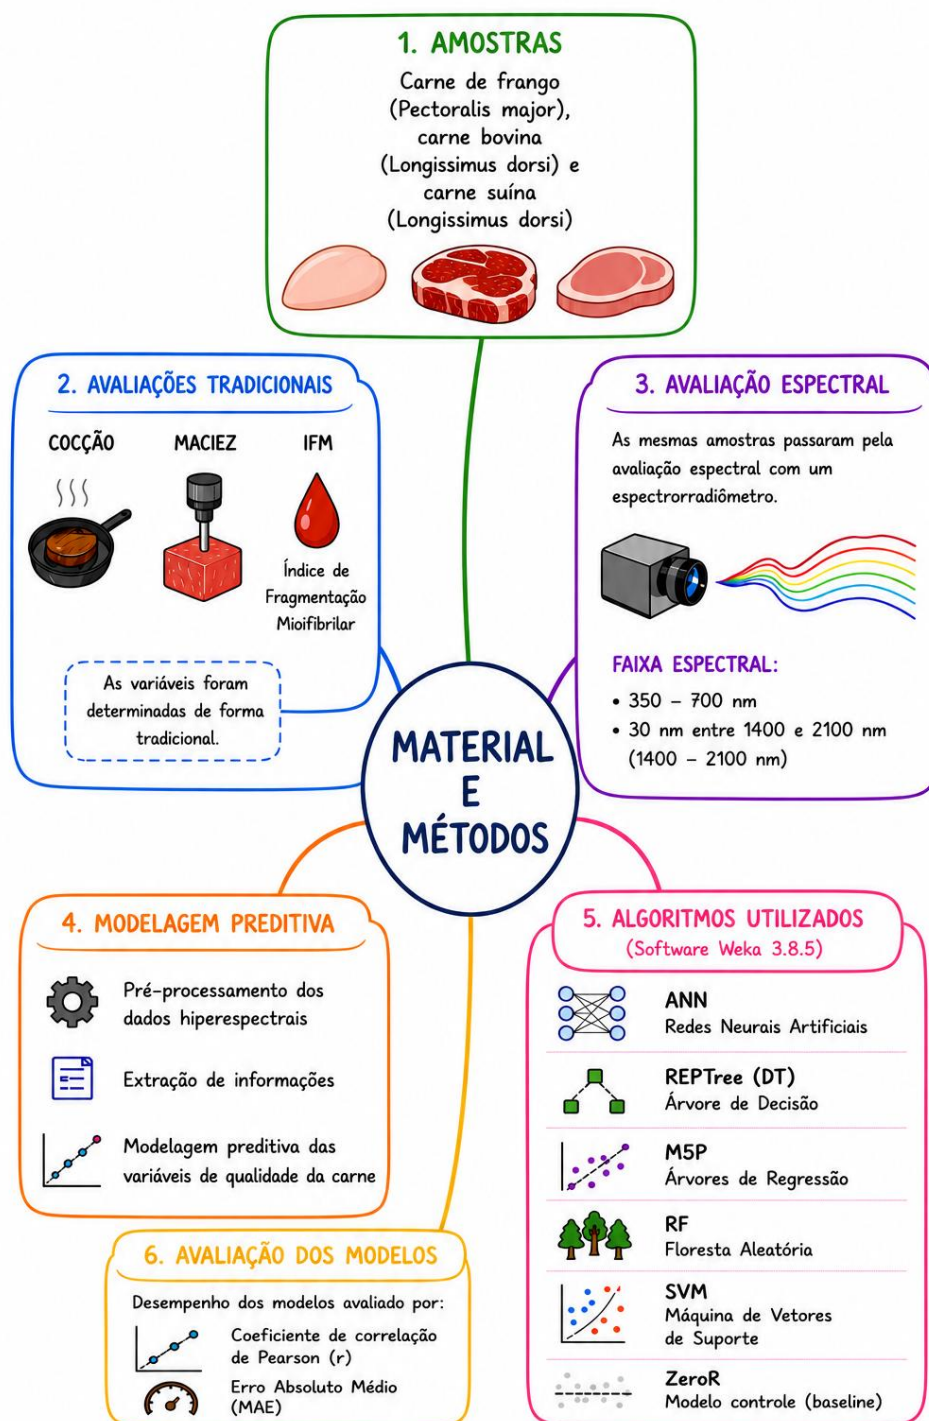
Esses métodos permitem um controle de qualidade mais eficiente e em tempo real, garantindo produtos mais seguros, frescos e padronizados. Como resultado, o consumidor tem acesso a carnes de melhor qualidade, com melhora na satisfação durante o consumo. Com isso, é possível identificar rapidamente variações indesejáveis nos produtos, garantindo carnes mais seguras, frescas e padronizadas. Além disso, reduzem a necessidade de análises destrutivas, evitando desperdícios e contribuindo para maior sustentabilidade no setor.

Para o consumidor, os benefícios são diretos: acesso a produtos com melhor qualidade sensorial (como cor, maciez e suculência), maior confiabilidade quanto às características informadas

no rótulo e menor risco de adquirir carnes com defeitos tecnológicos, como excesso de perda por cocção ou textura inadequada. Outro ponto importante é a possibilidade de maior rastreabilidade e transparência na produção, aumentando a confiança na origem e no processamento da carne.

Além disso, a adoção dessas tecnologias pode contribuir para maior padronização dos cortes disponíveis no mercado, reduzindo variações indesejáveis entre produtos e melhorando a experiência de consumo. Em conjunto, esses fatores resultam em maior satisfação, melhor custo-benefício e uma percepção mais positiva por parte do consumidor em relação aos produtos cárneos.

Os benefícios mencionados podem ser observados no fluxograma da metodologia deste estudo. Inicialmente, as amostras de carne bovina, suína e de frango foram avaliadas por métodos convencionais para determinação de parâmetros de qualidade. Em seguida, as mesmas amostras passaram por avaliação espectral utilizando espectrorradiometria, permitindo a obtenção rápida e não destrutiva de informações sobre a carne. Posteriormente, os dados espectrais foram processados por algoritmos de aprendizado de máquina, capazes de prever características de qualidade com elevada precisão. Essa abordagem demonstra como tecnologias não destrutivas podem substituir ou complementar análises laboratoriais tradicionais, reduzindo o tempo de avaliação, os custos operacionais e o desperdício de amostras, ao mesmo tempo em que contribuem para um controle de qualidade mais eficiente e para a disponibilização de produtos mais padronizados e confiáveis ao consumidor.



Fonte: Figura elaborada pelo autor com auxílio do ChatGPT (OpenAI), mediante “prompt” autoral, sendo o conteúdo revisado, validado e interpretado pelo autor.

CAPÍTULO 6 – CONSIDERAÇÕES FINAIS

As considerações finais desta dissertação demonstraram que a espectrorradiometria associada a algoritmos de aprendizado de máquina apresenta potencial para a avaliação de diferentes parâmetros de qualidade da carne. Nos dois capítulos desenvolvidos, os modelos foram capazes de prever atributos importantes da carne bovina, suína e de frango, como pH, perda por cocção, maciez, índice de fragmentação miofibrilar, pigmentos musculares e parâmetros de cor, evidenciando a capacidade dos dados espectrais em captar variações estruturais e químicas do tecido muscular.

No primeiro capítulo, cujo objetivo foi avaliar algoritmos de aprendizado de máquina aplicados a imagens hiperespectrais na predição de parâmetros físico-químicos da carne bovina, os modelos supervisionados apresentaram desempenho superior ao modelo controle, destacando-se principalmente os algoritmos M5P e Random Forest, que obtiveram melhores resultados para a maioria das variáveis analisadas.

No segundo capítulo, o objetivo foi avaliar diferentes modelos de aprendizado de máquina na predição de atributos qualitativos da carne de frango e suína a partir de dados espectrais. Os resultados demonstraram predominância do modelo M5P para variáveis relacionadas à qualidade tecnológica e parâmetros de cor, enquanto o Random Forest apresentou melhor desempenho para os pigmentos musculares.

De modo geral, os resultados reforçam o potencial da integração entre técnicas espectrais e aprendizado de máquina como ferramenta inovadora para avaliação da qualidade da carne, podendo futuramente complementar ou substituir métodos tradicionais, especialmente em aplicações que demandem rapidez, eficiência e análises não destrutivas.