

**UNIVERSIDADE FEDERAL DE VIÇOSA**

**ALINE RABELLO CONCEIÇÃO**

**IMAGENS TERMOGRÁFICAS DE CARÇAÇAS BOVINAS PARA PREDIÇÃO DA  
TEMPERATURA E PH DO *LONGISSIMUS THORACIS***

**VIÇOSA MG**

**2024**

**UNIVERSIDADE FEDERAL DE VIÇOSA**

**ALINE RABELLO CONCEIÇÃO**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Zootecnia para obtenção do título de *Magister Scientiae*.

Orientadora: Erica Beatriz Schultz

**VIÇOSA MG**

**2024**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade  
Federal de Viçosa - Campus Viçosa**

T

C744i  
2024

Conceição, Aline Rabello, 1999-

Imagens termográficas de carcaças bovinas para predição da temperatura e pH do *Longissimus thoracis* / Aline Rabello Conceição. – Viçosa, MG, 2024.

1 dissertação eletrônica (49 f.): il. (algumas color.).

Orientador: Erica Beatriz Schultz.

Dissertação (mestrado) - Universidade Federal de Viçosa, Departamento de Zootecnia, 2024.

Referências bibliográficas: f. 38-42.

DOI: <https://doi.org/10.47328/ufvbbt.2024.237>

Modo de acesso: World Wide Web.

1. Bovinos - Carcaças. 2. Aprendizado do computador. 3. Termografia. I. Schultz, Erica Beatriz, 1992-. II. Universidade Federal de Viçosa. Departamento de Zootecnia. Programa de Pós-Graduação em Zootecnia. III. Título.

CDD 22. ed. 636.2


**ALINE RABELLO CONCEIÇÃO**

**IMAGENS TERMOGRÁFICAS DE CARÇAÇAS BOVINAS PARA PREDIÇÃO DA  
TEMPERATURA E PH DO *LONGISSIMUS THORACIS***

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Zootecnia para obtenção do título de *Magister Scientiae*.

Orientadora: Erica Beatriz Schultz


APROVADA: 18 de março de 2024

Documento assinado digitalmente  
 **ALINE RABELLO CONCEICAO**  
Data: 09/07/2024 11:27:11-0300  
Verifique em <https://validar.iti.gov.br>

---

Aline Rabello Conceição

Autor(a)

Documento assinado digitalmente  
 **ERICA BEATRIZ SCHULTZ**  
Data: 09/07/2024 11:33:31-0300  
Verifique em <https://validar.iti.gov.br>

---

Prof.: Erica Beatriz Schultz

(Orientadora)

(UFV)

## **AGRADECIMENTOS**

A Deus por estar ao meu lado todos os dias e ter me mantido firme na realização deste sonho.

A minha mãe e mestre, pelos conselhos profissionais e pessoais, pelo colo ilimitado e por me aproximar de Deus, graças a vocês esse trabalho foi concluído.

Ao meu pai pelo apoio e orgulho que sente das minhas conquistas.

As minhas irmãs, Amanda e Angélica por serem meu refúgio e minha certeza de que não estarei sozinha nessa caminhada.

A minha avó Marta, sua presença me ensinou muito sobre paciência, mas sua partida me ensinou ainda mais sobre dar às coisas o valor que elas merecem, e assim valorizar o que de fato é essencial.

Ao Otto, minha companhia e minha alegria diária ao chegar em casa.

À Amanda Coeli, que merecia metade deste título, que esteve presente em cada etapa e que se comprometeu ao trabalho como se fosse dela. Minha gratidão eterna por tudo que você fez e faz por mim.

Ao Pedro pela amizade leve e divertida, mas também pelo comprometimento com a nossa pesquisa.

As minhas melhores amigas, Letícia, Paloma, Bianca e Ana Peres, por serem aconchego e alegria na minha vida.

Aos demais amigos e familiares por me ouvirem, apoiarem e as vezes darem o merecido puxão de orelha.

A Érica pela orientação prestada desde a escolha a dedo das disciplinas até a correção de cada vírgula da escrita.

Aos mestrandos e doutorandos, professores e funcionários da UFV, que de alguma forma me ajudaram e compartilharam seus conhecimentos comigo.

Aos meus queridos estagiários, espero ter contribuído para a formação de vocês.

A FAPEMIG (Fundação de Amparo à Pesquisa do Estado de Minas Gerais), ao apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) e a toda população brasileira por financiarem a pesquisa nas universidades.

A PPG Zootecnia, em especial a Fernanda por ser tão solícita e prestativa.

Aos profissionais da saúde que cuidaram da minha saúde física e mental.

Por fim, aos animais de produção que tem todo o meu respeito e gratidão.

*“É justo que muito custe o que muito vale”. (Santa Teresa de Jesus)*

## RESUMO

CONCEIÇÃO, Aline Rabello, M.Sc., Universidade Federal de Viçosa, março de 2024. **Imagens termográficas de carcaças bovinas para predição da temperatura e pH do *Longissimus thoracis***. Orientadora: Erica Beatriz Schultz.

Objetivou-se prever a temperatura e o pH do *Longissimus thoracis* de carcaças bovinas com base em imagens termográficas e no peso da carcaça quente. Imagens térmicas de 102 carcaças de carne bovina foram usadas para extrair características de temperatura. O algoritmo de aprendizado de máquina, *Random Forest* foi ajustado para a predição. As predições da temperatura *Longissimus thoracis* da carcaça quente foram obtidas com um coeficiente de determinação ( $R^2$ ) de 0,06, erro de raiz quadrada média (RMSE) de 2,13 e erro absoluto médio (MAE) de 1,55. O peso da carcaça contribuiu para a predição da temperatura da carcaça resfriada, especialmente com imagens obtidas às 0h ( $R^2 = 0,68$ , MAE = 1,12 e RMSE = 1,34) e 24h ( $R^2 = 0,78$ , MAE = 1,02 e RMSE = 1,22). Ambos os modelos apresentaram precisão e exatidão. O pH *Longissimus thoracis* da carcaça quente foi predito com precisão e exatidão usando dados extraídos de imagens às 0h ( $R^2 = 0,82$ , MAE = 0,11, RMSE = 0,13). Da mesma forma, o pH às 24h na carcaça resfriada foi predito com dados de imagens capturadas às 0h e o peso da carcaça quente ( $R^2 = 0,70$ , MAE = 0,19, RMSE = 0,24). Assim, este estudo demonstra a viabilidade de prever o pH e a temperatura do *Longissimus thoracis* de carcaças bovinas usando recursos de imagens termográficas e o peso da carcaça quente.

**Palavras-chave:** Aprendizado de máquina, Carne bovina, Precisão, Termografia.

## ABSTRACT

CONCEIÇÃO, Aline Rabello, M.Sc., Universidade Federal de Viçosa, March, 2024. **Thermographic images of bovine carcasses for predicting the temperature and pH of the *Longissimus thoracis***. Adviser: Erica Beatriz Schultz.

This study aimed to predict the temperature and pH of *Logissimus thoracis* of beef carcasses based on thermographic images and hot carcass weight. Thermal images of 102 beef carcasses were used to extract temperature features. The Random Forest machine learning (ML) algorithm was fine-tuned for prediction. Accurate predictions of hot carcass temperature were achieved with a coefficient of determination ( $R^2$ ) of 0.06, root-mean-square error (RMSE) of 2.13 and mean absolute error (MAE) of 1.55. Carcass weight played a considerable role in predicting chilled carcass temperature, particularly with images taken at 0 h ( $R^2 = 0.68$ , MAE = 1.12, and RMSE = 1.34) and 24 h ( $R^2 = 0.78$ , MAE = 1.02, and RMSE = 1.22). Both models exhibited precision and accuracy. The pH of the hot carcass was successfully predicted with precision and accuracy using data extracted from images at 0h ( $R^2 = 0.82$ , MAE = 0.11, RMSE = 0.13). Similarly, the pH of the cold carcass could be predicted using data from images captured at 0 h and the weight of the hot carcass ( $R^2 = 0.70$ , MAE = 0.19, RMSE = 0.24). Thus, this study demonstrates the feasibility of predicting pH and temperature using features from thermographic images and hot carcass weight.

**Keywords:** Accuracy, Beef, Machine learning, Thermography

**Acknowledgements:** Fundação de Amparo à Pesquisa do Estado de Minas Gerais (Process: RED-00172-22, APQ-01928-22 and Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES, PROEX 32002017011P9).

## SUMÁRIO

1. Introdução geral.....	8
2. Revisão de literatura.....	9
2.1. Influência da temperatura e do pH das carcaças na qualidade da carne .....	9
2.2. Uso de imagens nas avaliações de qualidade da carne .....	12
2.3. Aprendizado de máquinas: <i>Random Forest</i> .....	16
3. Referências .....	18
Thermal images of surface bovine carcasses to predict temperature and pH of longissimus thoracis .....	26

## 1. Introdução geral

A adoção de tecnologias na produção animal é uma alternativa viável para atender a demanda em quantidade e qualidade por produtos de origem animal. As tecnologias permitem a otimização da produção e a rastreabilidade dos processos. Na cadeia produtiva da carne a modernização provê melhorias ao bem-estar animal, à preservação do meio ambiente e à segurança alimentar. Isto pois, a maioria dos métodos de avaliação e monitoramentos tradicionais demandam tempo, mão-de-obra e são invasivos.

Nos frigoríficos, o pH e a temperatura das carcaças são os parâmetros de maior significância para a qualidade da carne no *post mortem*. O pH pós resfriamento interfere nas características organolépticas da carne, como suculência, tenacidade e cor (WEN-SONG et al., 2019). O monitoramento da temperatura durante o resfriamento é importante para assegurar o declínio do pH e evitar a proliferação de microrganismos deteriorantes. Tradicionalmente estes parâmetros são monitorados de forma manual, por um profissional com o auxílio de um pHmetro e de um termômetro.

Devido a importância destes parâmetros é emergente que um método automatizado seja implementado para o monitoramento do pH e temperatura da carcaça, de modo a reduzir o contato humano com o produto, o potencial risco de contaminação e os custos com mão de obra. O uso das imagens se destaca como uma das tecnologias mais promissoras na produção animal por ser não invasiva, rápida, obtida em tempo real e com bom custo-benefício (OLIVEIRA et al., 2021).

Algumas tecnologias adotadas na avaliação das carcaças são: as câmeras RGB (*red, green, blue*) e/ou tridimensionais e termográficas para análise de vídeo imagem, absorciometria de raio-x de dupla energia (DEXA), ultrassonografia, tomografia computadorizada e ressonância magnética (SILVA et al., 2020). As câmeras convencionais e termográficas se destacam devido ao baixo custo e portabilidade. Segundo Pabiou et al. (2011) o uso de câmeras nos frigoríficos, em pontos estratégicos da linha de processamento, permite a extração de características das imagens, como composição tecidual, marmoreio e temperaturas.

As imagens geradas por termografia infravermelha (TIV) têm o potencial de tornar o monitoramento das temperaturas mais preciso, uma vez que são geradas temperaturas médias com base em um maior número de pontos que o método tradicional de aferição. Portanto, poderia ser utilizada para o monitoramento da temperatura das carcaças. E baseado na estreita relação entre a temperatura e o pH no pré rigor mortis, é possível que uma técnica que funcione para a temperatura também possa ser usada para o pH. A automatização dos monitoramentos nos frigoríficos permite a aquisição de maior volume de dados, havendo perspectiva de aumento na adesão de tecnologias, a fim de garantir a qualidade da carne.

Um dos desafios para a implementação das tecnologias em indústrias é a necessidade de processamento e armazenamento do grande volume de dados coletados, para gerar informações. Para este fim, destacam-se as ferramentas de inteligência artificial, como os algoritmos de aprendizado de máquinas supervisionado, com grande capacidade analítica. Os algoritmos aprendem tarefas por meio do treinamento e teste com base no conjunto de dados. O desempenho deles pode ser avaliado por métricas de erro, como o erro médio absoluto (MAE) e a raiz quadrada do erro médio (RMSE), e coeficiente de determinação ( $R^2$ ). Ajustes podem ser realizados para viabilizar a implantação das tecnologias aos ambientes, uma vez que a adaptabilidade é importante na produção animal.

A motivação deste trabalho foi a ausência de estudos que utilizem a TIV em carcaças bovinas para prever a temperatura interna e o pH. Para isto, realizamos uma breve revisão sobre os pontos que foram cruciais para o desenvolvimento da pesquisa, como a importância do pH e da temperatura, o uso de imagens na ciência da carne e o aprendizado de máquinas supervisionado. O objetivo foi prever a temperatura interna e o pH do *Longissimus dorsi* de carcaças bovinas a partir de atributos de imagens termográficas superficiais associadas ao peso da carcaça quente.

## 2. Revisão de literatura

### 2.1. Influência da temperatura e do pH das carcaças na qualidade da carne

Nos bovinos a conversão do músculo em carne ocorre nas primeiras 24h *post mortem*, devido a ação da via glicolítica, que em anaerobiose produz energia (ATP) e ácido lático a partir do glicogênio (WARRISS, 1990). O acúmulo de lactato e íons hidrogênio resulta na redução do pH, de 7 no músculo para 5,3-5,8 na carne (SMULDERS et al., 1992). A taxa de declínio do pH pode variar devido o tipo de fibra muscular, ou seja, a quantidade de fibras glicolíticas e oxidativas (HAMBRECHT et al., 2005). Por exemplo, carcaças de bovinos precoces confinados com dietas de alto grão têm maior quantidade de fibras glicolíticas e por isto o pH reduz mais rapidamente nas primeiras horas *post mortem*. Ao contrário dos animais mais velhos, que devido o metabolismo das fibras oxidativas, a queda do pH é lenta nas primeiras horas (WARRISS, 1990).

Outros fatores intrínsecos aos animais podem modificar a taxa de declínio do pH, como a raça do animal (SHACKELFORD et al., 1994) e a quantidade de glicogênio muscular (IMMONEN e PUOLANNE, 2000). Fatores ambientais também moldam o comportamento do pH das carcaças, como as condições do ambiente da maturação sanitária, a estimulação elétrica e o resfriamento (MARSH et al., 1987).

A taxa de resfriamento e o declínio do pH pré *rigor mortis* são determinantes da qualidade da carne (HAMOEN, VOLLEBREGT e VAN DER SMAN, 2013). A temperatura por proporcionar o ambiente ideal para a redução do pH, e o pH por ser determinante dos aspectos intrínsecos da carne, como coloração, maciez e sabor, os quais são decisivos no momento da escolha do consumidor (WEN-SONG et al., 2019). Além disto, o resfriamento inicial é essencial para a segurança alimentar, já que o pH (7) e a temperatura (38°C) da carcaça logo após o abate é um ambiente propício para a proliferação de microrganismos patogênicos e deteriorantes.

Entretanto, as reações enzimáticas responsáveis pela conversão do músculo em carne são desaceleradas em baixas temperaturas, o que pode causar a redução da glicólise anaeróbica e da taxa de declínio do pH (AALHUS et al., 2002). Já é bem estabelecido na literatura que a qualidade final da carne depende da janela entre pH e temperatura no *post mortem* (HAMOEN, VOLLEBREGT e VAN DER SMAN, 2013).

De modo que, o resfriamento inicial das carcaças deve ser lento pois temperaturas mais amenas favorecem a redução do pH (BENDALL, 1973). Segundo Hannula e Puolanne (2004) o pH deve ser inferior a 5,7 antes que a temperatura atinja 7°C.

A taxa de resfriamento pode variar devido ao peso e ao acabamento da carcaça (MAPLES, LUSK e DESCASCAR, 2018), e dentro de uma mesma carcaça devido a localização anatômica do músculo (STOLOWSKI et al., 2006) e gordura subcutânea. Quanto maior a massa e a área superficial da carcaça maior a quantidade de energia a ser transferida durante o resfriamento (HIPPE et al., 1991). O mesmo ocorre com a quantidade de gordura, que funciona como isolante térmico, dificultando a troca de calor com o meio. Músculos mais profundos, carcaças pesadas e gordas podem passar pelo evento caracterizado por Warner et al. (2009) como alta temperatura (acima de 35º) e baixo pH (menor que 6) devido à maior dificuldade de se resfriarem.

Maples, Lusk e Descascar (2018) relatam que tem se tornado constante a dificuldade dos frigoríficos em resfriar as carcaças de modo efetivo em 24h devido ao aumento da massa delas nas últimas décadas. Isto pois, as condições de resfriamento foram padronizadas a muitos anos atrás, quando as carcaças eram mais leves e mais magras. Em suínos, Kaliszan et al. (2005) constatou que a taxa de resfriamento das carcaças leves tem comportamento exponencial, enquanto os músculos mais profundos de grandes carcaças têm decaimento sigmoide da temperatura. Isto ilustra a diferença da taxa de resfriamento das carcaças em decorrência da musculosidade.

Warner et al. (2009) demonstrou uma estreita relação entre temperaturas demasiadamente altas e baixo pH no pré rigor mortis com a maciez da carne. Relataram redução da força de cisalhamento nos primeiros 10 dias, e desnaturação das proteínas responsáveis pelo amaciamento por envelhecimento após os 30 dias (WARNER et al., 2009). No entanto, a maior problemática envolvida no resfriamento lento das carcaças, não é o pH ou a maciez, e sim a proliferação de microorganismos patogênicos devido à alta temperatura. Por outro lado, métodos de resfriamento acelerados reduzem a proliferação, mas podem causar encurtamento de sarcômero, principalmente em animais com maior quantidade de fibras oxidativas (OLSSON et al., 1994.), o que prejudica a maciez da carne (MARSH, 1977). Na tentativa de evitar este fenômeno, Savell, Mueller, Baird (2005) orientam que

enquanto o pH estiver maior que 6,2 a temperatura da carcaça deve estar maior que 10°C.

Além dos danos à qualidade da carne já citados, existem as preocupações de custo econômico quanto aos métodos de resfriamento, como o consumo de energia pela indústria, perda de peso da carcaça e a regulamentação quanto às exigências dos mercados exportadores (ZHANG et al., 2019). A inadequação da janela pH/temperatura resulta em maior contaminação microbiológica, em redução da desnaturação proteica, que é responsável pelo amaciamento da carne, e em carne DFD (*dark, firm and dry*), caracterizada por ser seca, dura, escura e com alta capacidade de retenção de água (MALTIN et al., 2003, OFFER et al., 1989).

Em decorrência dos diversos fatores que podem alterar o comportamento do pH e causar a deterioração da qualidade da carne é emergente que técnicas de monitoramento individualizado do pH e temperatura sejam desenvolvidas. Uma vez que, tradicionalmente nos frigoríficos eles são mensurados de forma manual por um profissional, com auxílio de um termômetro e de um pHmetro, por meio de amostragem e contato direto com o produto. Esta etapa tem como objetivo verificar se o resfriamento e a redução do pH foram efetivos e se o produto está adequado para comercialização. Por exemplo, a União Europeia exige temperatura máxima de 7°C e pH 5,8 das carcaças após 24h de resfriamento antes de encaminhadas para o processamento (JAMES, 1996; BOWATER et al., 2001). Entretanto, o atual monitoramento no Brasil é pouco preciso, pois não é realizado em todas as carcaças, demorado e invasivo, o que contribui para a contaminação bacteriana.

Uma alternativa viável para driblar estes desafios é a implementação de tecnologias nos frigoríficos, que permitam a obtenção destes parâmetros de forma ágil e remota, reduzindo o contato humano com o produto e aumentando a confiabilidade dos dados, já que permitiria o monitoramento em todas as carcaças. Além disso, as novas técnicas devem permitir a classificação das carcaças de acordo com a legislação vigente no país ou exigência do mercado exportador.

## **2.2. Uso de imagens nas avaliações de qualidade da carne**

As tecnologias não destrutivas já têm sido amplamente utilizadas na pecuária, com intuito de automatizar processos, reduzindo os custos com mão de obra e otimizando a tomada de decisão. Dentre elas, as tecnologias de obtenção de imagens RGB têm sido aplicadas na obtenção de biométricas corporais, avaliações

de qualidade da carne e saúde animal. O aprendizado de máquinas tem contribuído para viabilizar o uso destas, pois facilita o processamento e utilização dos dados obtidos. Como a visão computacional, que é uma ferramenta eficaz na predição e classificação dos fenótipos dos animais conforme revisado por Oliveira et al. (2021).

Devido a importância do peso corporal para a tomada de decisão, por exemplo sobre o ponto ideal de abate, o uso de imagens para extração de biométricas corporais é uma alternativa substituta às balanças, que facilita o manejo e contribui para o bem-estar animal. Fernandes et al. (2020) demonstraram o bom desempenho dos sistemas de visão computacional na predição do peso de suínos, e Cominotte et al. (2020) em bovinos. Outra vantagem deste sistema é que ele permite a avaliação de características externas da carne, como cor e gordura (SHI et al., 2021). Conforme veremos, modelos estatísticos modernos e algoritmos de aprendizados de máquinas contribuirão para a adaptação e desempenho das técnicas de imagens em diversos ambientes.

Echegaray et al. (2022) enfatizam a emergência do desenvolvimento de sistemas inovadores e eficientes que minimizem o desperdício e facilitem o abastecimento mundial de alimentos. Além disto, destacam que a individualidade dos animais e heterogeneidade dos ambientes é um desafio para a automatização dos frigoríficos. Por isto, os sensores óticos são preferidos nas linhas de processamento, seja para avaliações, inspeções ou predições. Eles proporcionam medições em tempo real, maior volume de dados, menor subjetividade, e maior segurança alimentar (HOFFMANN et al., 2013; OLIVEIRA et al., 2021).

Uma imagem digital é uma matriz estruturada finita formada por pixels, que codifica cores e luz para cada ponto (FERNANDES, DÓREA e ROSA, 2020; GONZALES e WINTZ, 1987). Através do processamento da imagem digital é possível equalizar, filtrar ou transformá-la com o objetivo de extrair informações. A extração de informações da imagem produz o que chamamos de descritores que podem ser, por exemplo, áreas, volume e comprimentos. Após a aquisição de dados da imagem é possível compilar todas as informações com intuito de construir um banco de dados, que em conjunto com ferramentas de inteligência artificial realizará predições, classificações e/ou descrições (CORRÊA, 2015).

Dentre os sensores óticos, as câmeras digitais padrão são as mais utilizados na zootecnia de precisão (ECHEGARAY et al., 2022), devido a portabilidade, baixo custo e facilidade de processamento das imagens. Daniel et al. (2020) propuseram

um sistema de classificação automático de carcaças bovinas por meio de imagens e inteligência artificial. O sistema é composto por uma câmera de alta resolução, processadores, e sensor registrador de temperatura, umidade e peso na linha de processamento. Foi obtido alta precisão e velocidade de classificação 10x superior à de um especialista humano, entretanto, devido à alta resolução da câmera, exige-se também alta capacidade analítica e de processamento (DANIEL et al., 2020). Também motivados em reduzir custos e facilitar análises, Ruedt, Gibis e Weiss (2020) desenvolveram um método de quantificação de iridescência (coloração de arco-íris) na carne apenas com uma câmera digital e um software de código aberto. A técnica proposta demonstrou concordância com a análise sensorial, podendo ser implementada em substituição ou adição à tradicional (RUEDT, GIBIS e WEISS, 2020).

Outras ferramentas tecnológicas também têm sido testadas para fenotipagem e avaliações de produtos cárneos, como os dispositivos de imagens 3D, sensores hiperespectral no infravermelho próximo (NIR) e termografia infravermelho. Adamczak et al. (2018) scanearam em 3D carcaças de frango em diversas secções transversais, o que permitiu testar qual a área com maior correlação e estimar o peso do peito de forma precisa. Em bovinos de corte, foi utilizado um Kinect na obtenção das imagens tridimensionais para obter peso vivo e peso da carcaça quente (COMINOTTE et al., 2023). Devido à alta variabilidade da acurácia dos modelos aplicados, os autores alegam que a técnica é útil apenas quando aplicada em lotes para obter o peso médio.

A maioria dos estudos encontrados com tecnologias na qualidade da carne se baseiam no uso do NIR. Isto pois, os dados espectrais são reflexo da composição química, e por isso a técnica de eletroscopia de infravermelho é a recomendada para detecção de frescor da carne e grau de contaminação e degradação (SHI et al., 2021). Imagens hiperespectrais tem potencial em prever de forma não destrutiva atributos de qualidade da carne bovina fresca de forma precisa, como cor, pH e maciez (ELMASRY, SUN e ALLEN 2012, WU et al., 2012). Segundo ElMasry, Sun e Allen (2012) o sistema carece apenas de melhorias na velocidade de coleta e no processamento das imagens para que possa ser implementado nas linhas comerciais.

Mais recentemente, Savoia et al. (2020) testou a viabilidade de implementação de espectrômetros portáteis, Vis-NIRS e Micro-NIRS nos

abatedouros para prever características de qualidade da carne. As coletas foram realizadas nas carcaças bovinas antes do início da desossa, no *Longissimus dorsi*, e foi possível prever a cor e a perda por gotejamento. Os autores destacam que o NIR pode contribuir para avanços no melhoramento genético, já que realiza previsões de fenótipos explorados na bovinocultura de corte (SAVOIA et al., 2020).

Outra variável de grande relevância para a indústria da carne é a temperatura. Esta também pode ser extraída durante o processamento das imagens térmicas, as quais são geradas por dispositivos capazes de captar carga infravermelha sem contato, o que permite extrair temperaturas proporcionais às do corpo imageado (WARRIS et al., 2006). A TRI já é utilizada na saúde de bovinos em diagnósticos de inflamações locais, como mastite (COLAK et al., 2008) e claudicações (ALSAAOD e BÜSCHER, 2012), estado térmico (HOFFMANN et al., 2013) e eficiência produtiva (MONTANHOLI et al., 2009).

Há décadas pesquisadores investigam o potencial dessa técnica, aplicada nos animais como indicador de depreciação futura à qualidade da carne. Schaefer et al. (1989) e Weschenfelder et al. (2013) realizaram medições com TRI em suínos com objetivo de prever variações na qualidade da carne, e concluíram que a técnica pode indicar o estado fisiológico do animal e ajudar a predizê-lo. De modo similar, Cuthbertson et al. (2020) realizaram em bovinos, mensurando a temperatura ocular dos bovinos por TRI nas fazendas de origem. A TRI indicou os animais de comportamento mais reativo, e que conseqüentemente são mais susceptíveis à redução da qualidade da carne.

O uso da TRI diretamente nas carcaças, nas linhas de processamento, ainda é pouco estudado. Em suínos, Costa et al. (2007) capturaram imagens termográficas dos pernis e concluíram apenas que é uma técnica útil para a identificação de bons pernis para maturação a seco. Em bovinos, um estudo exploratório de Hite et al. (2020) relataram que a TRI permite rápida coleta de imagens ao longo da linha de processamento e as correlações positivas encontradas entre a TRI e a temperatura por *data loggers* apontaram que a técnica auxilia na predição do resfriamento das carcaças. Corrêa (2019) correlacionaram a TRI das carcaças nos tempos 0h, 12h e 24h com os parâmetros laboratoriais qualitativos da carne, e devido à influência da temperatura em alguns deles, afirmaram que a técnica pode auxiliar na classificação das carcaças.

Devido à escassez de trabalhos não foram encontradas recomendações assertivas sobre o real potencial da TRI como indicador direto de qualidade da carne e da carcaça. Para isto devem ser realizadas pesquisas com bancos de dados extensivos à heterogeneidade das carcaças bovinas mundiais, e métodos de processamento abrangentes que gerem informações a partir dos dados e permitam a tomada de decisão. Além disto, é emergente validações nos frigoríficos que confirmem a adaptabilidade da tecnologia ao ambiente e à velocidade das linhas de processamento.

### **2.3. Aprendizado de máquinas: *Random Forest***

As ferramentas de inteligência artificial (IA) consistem em aprender por meio dos dados, interpretá-los e utilizar deste aprendizado para realizar objetivos específicos. A IA é fundamentada em experiências, ideias, razões e algoritmos. Compõe, portanto, a IA o aprendizado de máquinas, *deep learning*, planejamento automatizado e gestão do conhecimento (GÉRON, 2019). Na produção animal as principais ferramentas de IA utilizadas são o aprendizado de máquina (AM) e o *deep learning*.

O AM dá aos computadores a capacidade de aprender sem de fato serem programados (MAHESH, 2019). Este é formado por algoritmos supervisionados e não-supervisionados que podem descrever padrões, reduzir a dimensionalidade de dados, realizar predições e classificações (GÉRON, 2019). Os algoritmos de AM não supervisionado são compostos pelas técnicas de análise de agrupamento, redução de dimensionalidade, aprendizado de regras por associação e detecção de anomalias e novidades (GÉRON, 2019). Os algoritmos supervisionados serão detalhados pois são mais usuais nas pesquisas de produção animal.

O objetivo do AM supervisionado é usar os preditores (*inputs*), para obter as respostas (*outputs*). Ou seja, os dados inseridos treinam o algoritmo para fornecer uma resposta, que pode ser obtida por regressão, para respostas quantitativas, ou classificação, para qualitativas (HASTIE et al., 2009). O AM supervisionado se inicia com o estudo da problemática, organização do banco de dados e seleção do modelo. Os modelos de regressão são treinados e testados com um banco de dados, para em seguida serem capazes de fornecer previsões baseadas em novos dados. Um exemplo prático do AM supervisionado são os sites que dão uma recomendação baseada no histórico do usuário. É importante destacar que não

existe um algoritmo perfeito para um determinado problema, os modelos devem ser testados quanto a adaptabilidade às variáveis preditoras disponíveis, ao ambiente e a natureza do problema (MAHESH, 2019).

O *Random Forest* (RF) é um dos algoritmos mais poderosos e populares do AM supervisionado, sendo encontrados estudos nas diversas áreas de conhecimento, como economia, medicina, geografia, entre outros. Isto pois, a combinação de árvores classificadoras, torna o algoritmo rápido, preciso e não produz sobreajuste (LIU, WANG & ZHANG, 2012). O RF pode realizar predição (regressão) e classificação, onde as variáveis respostas assumem valor numérico e binário, respectivamente.

Ao realizar predições ele se baseia na construção de diversas árvores aleatórias de decisão, o que reduz a variância da previsão fornecida por uma única árvore e fornece uma previsão final a partir da média da floresta. O que resulta em uma previsão mais precisa, devido à aleatoriedade de cada árvore e ao conjunto de preditores, evitando o sobreajuste (GENUER et al., 2020). Ele pondera a utilização das variáveis preditoras de acordo com as de maior importância para o desempenho, sendo que nenhuma variável é ignorada ou retirada do modelo, como acontece em outros algoritmos, como o *Gradient Boosting* (HASTIE et al., 2009). Além disto permite a identificação e construção do gráfico de importância das variáveis (GÉRON, 2019).

O RF é de fácil utilização pois são poucos os parâmetros a serem ajustados para a otimização, sendo *mtry* e *ntree* os principais (GENUER et al., 2020). O *mtry*, representa o número de variáveis a serem amostradas em cada divisão (nó), e é o mais importante, uma vez que o número de variáveis pode modificar o desempenho do modelo. O *ntree* representa o número de árvores, e quanto mais árvores, melhor o desempenho. Entretanto, quanto mais árvores maior o tempo de processamento do RF, por isso o número de árvores deve ser decidido a partir do momento que adicionar árvores não melhorar o desempenho do modelo (GENUER et al., 2020; RANDOM FORESTS, 2018). E esta é uma das desvantagens do RF, a velocidade de processamento pode ser reduzida em um grande conjunto de dados e número de árvores.

O desempenho dos modelos de AM deve ser avaliado com a métrica adequada aos dados e ao propósito de uso do modelo. Por exemplo, a escolha da métrica de erro deve acordar com a distribuição esperada dos erros (HODSON,

2022). Chai e Draxler (2014) afirmam que uma combinação de métricas pode ser utilizada para obter uma melhor avaliação do desempenho dos modelos. Além disso, é importante revisar na literatura quais as métricas mais utilizadas tanto para algoritmo quanto para o objetivo do estudo. Por fim, a partir dos valores encontrados, afinamentos e ajustes nos hiperparâmetros podem ser realizados para a validação e implantação do modelo.

O coeficiente de determinação ( $R^2$ ), o erro médio absoluto (MAE), a raiz quadrada do erro médio (RMSE) são frequentemente utilizados em análises de regressão, sendo o  $R^2$  o preferido. Ele expressa, de 0 a 1, o quanto a variável resposta é determinada pelas variáveis independentes (CHICCO, WARRENS e JURMAN, 2021). Já nas métricas RMSE, MSE e MAE, o 0 representa o limite inferior, o ajuste perfeito do modelo, e não existe limite superior, o valor é crescente quanto pior o desempenho do modelo. O que é um desafio para interpretação, já que não há um valor limite que determine até onde o modelo tem desempenho satisfatório. Por exemplo, um  $R^2=0,8$  indica um modelo com boa acurácia preditiva, ao passo que um MAE=0,8 por si só, sem ter acesso a outros dados, não indica nada. As métricas de erro citadas não permitem interpretação apenas pelo valor, sem conhecer os dados e a unidade de medida, nem comparação entre estudos feitos com dados diferentes (CHICCO, WARRENS e JURMAN, 2021).

Não existe uma regra para quais medidas de avaliação devem ser utilizadas nas análises, mas é estabelecido uma preferência por uma combinação delas (CHAI e DRAXLER, 2014). Entretanto os estudiosos reforçam que é impossível afirmar sobre a qualidade geral do modelo apenas com base nos valores das métricas, deve-se avaliar o objetivo do estudo e a unidade de medida das variáveis independentes.

O uso de tecnologias inteligentes promete otimizar a criação animal, isto pois, elas têm alta capacidade de armazenamento e de processamento dos dados. O que tem sido utilizado na resolução de problemas e auxiliado na tomada de decisão dos produtores, por meio da integração com mecanismos de notificação remotos (NEETHIRAJAN, 2020). Acreditamos que além de reduzir custos e aumentar a eficiência, estas tecnologias possam auxiliar na compreensão de mecanismos complexos, como a conversão de músculo em carne.

### 3. Referências

AALHUS, Jennifer Lynn et al. Very fast chilling of beef carcasses. **Canadian Journal of Animal Science**, v. 82, n. 1, p. 59-67, 2002. <https://doi.org/10.4141/A01-020>

ADAMCZAK, Lech et al. The use of 3D scanning to determine the weight of the chicken breast. **Computers and Electronics in Agriculture**, v. 155, p. 394-399, 2018. <https://doi.org/10.1016/j.compag.2018.10.039>

ALSAAOD, M.; BÜSCHER, W. Detection of hoof lesions using digital infrared thermography in dairy cows. **Journal of Dairy Science**, v. 95, n. 2, p. 735-742, 2012. <https://doi.org/10.3168/jds.2011-4762>

ANDUEZA, Donato et al. Phenotyping of animals and their meat: applications of low-power ultrasounds, near-infrared spectroscopy, Raman spectroscopy, and hyperspectral imaging. **Lawrie's Meat Science**, p. 501-519, 2017. <https://doi.org/10.1016/B978-0-08-100694-8.00016-9>

BENDALL, J. R. The biochemistry of rigor mortis and cold-contraction. In: **Proceedings of the 19th European meeting of meat research workers**. 1973. p. 2-7.

BOWATER, F. J. Rapid carcass chilling plants compared to conventional systems. **Int. J. Refrig**, p. 1-6, 2001. Disponível em: [Rapid Carcass Chilling vs Conventional-libre.pdf \(d1wqtxts1xzle7.cloudfront.net\)](https://www.researchgate.net/publication/228211111_Rapid_Carcass_Chilling_vs_Conventional-libre.pdf). Acesso em: 12/01/2024

CHAI, Tianfeng; DRAXLER, Roland R. Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. **Geoscientific Model Development**, v. 7, n. 3, p. 1247-1250, 2014. <https://doi.org/10.5194/gmd-7-1247-2014>

CHICCO, Davide; WARRENS, Matthijs J.; JURMAN, Giuseppe. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. **PeerJ Computer Science**, v. 7, p. e623, 2021. <https://doi.org/10.7717/peerj-cs.623>

COLAK, Armağan et al. Early detection of mastitis using infrared thermography in dairy cows. **Journal of Dairy Science**, v. 91, n. 11, p. 4244-4248, 2008. <https://doi.org/10.3168/jds.2008-1258>

COMINOTTE, A. et al. Automated computer vision system to predict body weight and average daily gain in beef cattle during growing and finishing phases. **Livestock Science**, v. 232, p. 103904, 2020. <https://doi.org/10.1016/j.livsci.2019.103904>

COMINOTTE, Alexandre et al. Use of Biometric Images to Predict Body Weight and Hot Carcass Weight of Nellore Cattle. **Animals**, v. 13, n. 10, p. 1679, 2023. <https://doi.org/10.3390/ani13101679>

CORRÊA, Augusto Matos. **Termografia infravermelha para a avaliação de carcaça e qualidade de carne bovina**. 2019. 24 f. Dissertação (Mestrado em Zootecnia) - Universidade Federal de Viçosa, Viçosa. 2019. Disponível em: <https://locus.ufv.br//handle/123456789/26964>. Acesso em: 05/01/2024

CORRÊA, Priscilla Braga Pinheiro. **Estimativa da massa corporal de bovinos por meio de sensor de profundidade KINECT®**. Programa de Pós-Graduação em Engenharia Agrícola. Universidade Federal de Viçosa., 50p., 2015.

COSTA, Nanni et al. The use of thermography on the slaughter-line for the assessment of pork and raw ham quality. **Italian Journal of Animal Science**, v. 6, n. sup1, p. 704-706, 2007. <https://doi.org/10.1016/j.meatsci.2013.06.003>

DANIEL, H. et al. Non-invasive automatic beef carcass classification based on sensor network and image analysis. **Future Generation Computer Systems**, v. 113, p. 318-328, 2020. <https://doi.org/10.1016/j.future.2020.06.055>

ECHEGARAY, Noemí et al. Meat 4.0: Principles and applications of Industry 4.0 technologies in the meat industry. **Applied Sciences**, v. 12, n. 14, p. 6986, 2022. <https://doi.org/10.3390/app12146986>

ELMASRY, Gamal; SUN, Da-Wen; ALLEN, Paul. 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>

FERNANDES, Arthur FA et al. Comparison of data analytics strategies in computer vision systems to predict pig body composition traits from 3D images. **Journal of Animal Science**, v. 98, n. 8, p. skaa250, 2020. <https://doi.org/10.1093/jas/skaa250>

FERNANDES, Arthur Francisco Araújo; DÓREA, João Ricardo Rebouças; ROSA, Guilherme Jordão de Magalhães. Image analysis and computer vision applications in animal sciences: an overview. **Frontiers in Veterinary Science**, v. 7, p. 551269, 2020. <https://doi.org/10.3389/fvets.2020.551269>

GENUER, Robin et al. **Random forests**. Springer International Publishing, 2020.

GÉRON, Aurélien. **Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow**. Alta Books, 2019.

GONZALES, Rafael C.; WINTZ, Paul. **Digital Image Processing**. Addison-Wesley Longman Publishing Co., Inc., 1987.

HAMBRECHT, E. et al. Preslaughter handling effects on pork quality and glycolytic potential in two muscles differing in fiber type composition. **Journal of Animal Science**, v. 83, n. 4, p. 900-907, 2005. <https://doi.org/10.2527/2005.834900x>

HAMOEN, J. R.; VOLLEBREGT, H. M.; VAN DER SMAN, R. G. M. Prediction of the time evolution of pH in meat. **Food Chemistry**, v. 141, n. 3, p. 2363-2372, 2013. <https://doi.org/10.1016/j.foodchem.2013.04.127>

HANNULA, Tapio; PUOLANNE, Eero. The effect of cooling rate on beef tenderness: The significance of pH at 7 C. **Meat Science**, v. 67, n. 3, p. 403-408, 2004. <https://doi.org/10.1016/j.meatsci.2003.11.012>

HASTIE, Trevor et al. **The elements of statistical learning: data mining, inference, and prediction**. New York: springer, 2009.

HITE, L. M. et al. **Investigation on the Use of a FLIR (Forward Looking Infrared) Camera to Detect Relationships Between Internal and Surface Temperatures of Beef Carcasses During Chilling**. 2020. Disponível em: [Investigation on the Use of a FLIR \(Forward Looking Infrared\) Camera to Detect](#)

Relationships Between Internal and Surface Temperatures of Beef Carcasses During Chilling (sdstate.edu). Acesso em: 05/01/2024

HODSON, Timothy O. Root-mean-square error (RMSE) or mean absolute error (MAE): When to use them or not. **Geoscientific Model Development**, v. 15, n. 14, p. 5481-5487, 2022. <https://doi.org/10.5194/gmd-15-5481-2022>

HOFFMANN, Gundula et al. Monitoring the body temperature of cows and calves using video recordings from an infrared thermography camera. **Veterinary Research Communications**, v. 37, p. 91-99, 2013. <https://doi.org/10.1007/s11259-012-9549-3>

IMMONEN, K.; PUOLANNE, E. Variation of residual glycogen-glucose concentration at ultimate pH values below 5.75. **Meat Science**, v. 55, n. 3, p. 279-283, 2000. [https://doi.org/10.1016/S0309-1740\(99\)00152-7](https://doi.org/10.1016/S0309-1740(99)00152-7)

JAMES, S. The chill chain “from carcass to consumer”. **Meat Science**, v. 43, p. 203-216, 1996. [https://doi.org/10.1016/0309-1740\(96\)00066-6](https://doi.org/10.1016/0309-1740(96)00066-6)

KALISZAN, Michał et al. Verification of the exponential model of body temperature decrease after death in pigs. **Experimental Physiology**, v. 90, n. 5, p. 727-738, 2005. [10.1113/expphysiol.2005.030551](https://doi.org/10.1113/expphysiol.2005.030551)

LIU, Yanli; WANG, Yourong; ZHANG, Jian. New machine learning algorithm: Random forest. In: Information Computing and Applications: Third International Conference, ICICA 2012, Chengde, China, September 14-16, 2012. Proceedings 3. Springer Berlin Heidelberg, 2012. p. 246-252.

MAHESH, Batta. Machine learning algorithms-a review. **International Journal of Science and Research (IJSR)**. [Internet], v. 9, n. 1, p. 381-386, 2020. <https://www.ijsr.net/getabstract.php?paperid=ART20203995>

MALTIN, Charlotte et al. Determinants of meat quality: tenderness. **Proceedings of the Nutrition Society**, v. 62, n. 2, p. 337-347, 2003. <https://doi.org/10.1079/PNS2003248>

MAPLES, Joshua G.; LUSK, Jayson L.; PEEL, Derrell S. Unintended consequences of the quest for increased efficiency in beef cattle: When bigger isn't

better. **Food Policy**, v. 74, p. 65-73, 2018.  
<https://doi.org/10.1016/j.foodpol.2017.11.005>.

MARSH, B. B. The Basis of Quality in Muscle Foods The basis of tenderness in muscle foods. **Journal of Food Science**, v. 42, n. 2, p. 295-297, 1977.  
<https://doi.org/10.1111/j.1365-2621.1977.tb01485.x>

MONTANHOLI, Y. R. et al. On the determination of residual feed intake and associations of infrared thermography with efficiency and ultrasound traits in beef bulls. **Livestock Science**, v. 125, n. 1, p. 22-30, 2009.  
<https://doi.org/10.1016/j.livsci.2009.02.022>

NEETHIRAJAN, Suresh. The role of sensors, big data and machine learning in modern animal farming. **Sensing and Bio-Sensing Research**, v. 29, p. 100367, 2020. <https://doi.org/10.1016/j.sbsr.2020.100367>

OCDE/FAO, "Carne", in OECD-FAO Agricultural Outlook 2023-2032, OECD Publishing, Paris, 2023. <https://doi.org/10.1787/f01f6101-en>

OFFER, Gerald et al. The structural basis of the water-holding, appearance and toughness of meat and meat products. **Food Structure**, v. 8, n. 1, p. 17, 1989. Disponível em: ["The Structural Basis of the Water-Holding, Appearance and Toughness of" by Gerald Offer, Peter Knight et al. \(usu.edu\)](#) Acesso em: 29/12/2023

OLIVEIRA, Dario Augusto Borges et al. A review of deep learning algorithms for computer vision systems in livestock. **Livestock Science**, v. 253, p. 104700, 2021. <https://doi.org/10.1016/j.livsci.2021.104700>

OLSSON, Urban; HERTZMAN, Cecilia; TORNBERG, Eva. The influence of low temperature, type of muscle and electrical stimulation on the course of rigor mortis, ageing and tenderness of beef muscles. **Meat Science**, v. 37, n. 1, p. 115-131, 1994. [https://doi.org/10.1016/0309-1740\(94\)90149-X](https://doi.org/10.1016/0309-1740(94)90149-X)

PABIU, T. et al. Use of digital images to predict carcass cut yields in cattle. **Livestock Science**, v. 137, n. 1-3, p. 130-140, 2011.  
<https://doi.org/10.1016/j.livsci.2010.10.012>

RUEDT, Chiara; GIBIS, Monika; WEISS, Jochen. Quantification of surface iridescence in meat products by digital image analysis. **Meat Science**, v. 163, p. 108064, 2020. <https://doi.org/10.1016/j.meatsci.2020.108064>

SAVELL, J. W.; MUELLER, S. L.; BAIRD, B. E. The chilling of carcasses. **Meat Science**, v. 70, n. 3, p. 449-459, 2005. <https://doi.org/10.1016/j.meatsci.2004.06.027>

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

SCHAEFER, A. L. et al. Infrared thermography of pigs with known genotypes for stress susceptibility in relation to pork quality. **Canadian Journal of Animal Science**, v. 69, n. 2, p. 491-495, 1989. <https://doi.org/10.4141/cjas89-056>

SHACKELFORD, S. D. et al. Effect of biological type of cattle on the incidence of the dark, firm, and dry condition in the longissimus muscle. **Journal of Animal Science**, v. 72, n. 2, p. 337-343, 1994. <https://doi.org/10.2527/1994.722337x>

SHI, Yinyan et al. A Review on Meat Quality Evaluation Methods Based on Non-Destructive Computer Vision and Artificial Intelligence Technologies. **Food Science of Animal Resources**, v. 41, n. 4, p. 563, 2021. [10.5851/kosfa.2021.e25](https://doi.org/10.5851/kosfa.2021.e25)

SILVA, Severiano et al. Non-destructive imaging and spectroscopic techniques for assessment of carcass and meat quality in sheep and goats: A review. **Foods**, v. 9, n. 8, p. 1074, 2020. <https://doi.org/10.3390/foods9081074>

SMULDERS, F. J. M. et al. New technologies for meat and meat products. **Utrecht: Audet Tijdschriften**, v. 182, p. 186-188, 1992.

STOLOWSKI, G. D. et al. Factors influencing the variation in tenderness of seven major beef muscles from three Angus and Brahman breed crosses. **Meat Science**, v. 73, n. 3, p. 475-483, 2006. <https://doi.org/10.1016/j.meatsci.2006.01.006>

WARNER, R. D. et al. Factors influencing the incidence of high rigor temperature in beef carcasses in Australia. **Animal Production Science**, v. 54, n. 4, p. 363-374, 2014. <https://doi.org/10.1071/AN13455>

WARRISS, P. D. et al. Estimating the body temperature of groups of pigs by thermal imaging. **Veterinary Record**, v. 158, n. 10, p. 331-334, 2006. <https://doi.org/10.1136/vr.158.10.331>

WARRISS, Paul D. "The handling of cattle pre-slaughter and its effects on carcass and meat quality." **Applied Animal Behaviour Science**, v. 28, n. 1-2, p. 171-186, 1990. [https://doi.org/10.1016/0168-1591\(90\)90052-F](https://doi.org/10.1016/0168-1591(90)90052-F)

WEN-SONG, Wei et al. Research on detection of beef freshness parameters based on multi spectral diffuse reflectance method. **Spectroscopy and Spectral Analysis**, v. 39, n. 4, p. 1177-1185, 2019.

WESCHENFELDER, Angela V. et al. Use of infrared ocular thermography to assess physiological conditions of pigs prior to slaughter and predict pork quality variation. **Meat Science**, v. 95, n. 3, p. 616-620, 2013. <https://doi.org/10.4081/ijas.2007.1s.704>

WU, Jianhu et al. Prediction of beef quality attributes using VIS/NIR hyperspectral scattering imaging technique. **Journal of Food Engineering**, v. 109, n. 2, p. 267-273, 2012. <https://doi.org/10.1016/j.jfoodeng.2011.10.004>

ZHANG, Yimin et al. Effect of carcass chilling on the palatability traits and safety of fresh red meat. **Comprehensive Reviews in Food Science and Food Safety**, v. 18, n. 6, p. 1676-1704, 2019. <https://doi.org/10.1111/1541-4337.12497>

## **Thermal images of surface bovine carcasses to predict temperature and pH of longissimus thoracis**

Aline Rabello Conceição\*; Natalia Farias de Souza\*; Amanda Candian Coeli\*; Pedro Henrique Silva Braga\*; Eula Regina Carrara\*; Claudia Batista Sampaio\*; Mario Luiz Chizzotti\*; Erica Beatriz Schultz\*<sup>1</sup>

\* Department of Animal Science, Federal University of Viçosa, Viçosa, Minas Gerais, Brazil, 36570-900

<sup>1</sup> Correspondence author; E-mail address: erica.schultz@ufv.br

Current address: PH. Rolfs Ave, Viçosa, MG, Department of Animal Science, University Campus 36570-900, Brazil. Phone: +55 34988191369

### **Orcid Numbers:**

AR Conceição (0000-0003-4685-1284), NF Souza (0009-0006-6280-4575), AC Coeli (0000-0001-9207-6448), PHS Braga (0009-0006-6235-8309), ER Carrara (0000-0002- 3477-6929), CB Sampaio(0000-0002-7761-0232), ML Chizzotti (0000-0001-9770- 6891), EB Schultz (0000-0003-1916-2117).

### **ABSTRACT**

This study aimed use of infrared thermography images (IRT) to predict the temperature and pH of Longissimus thoracis (LT) of bovine carcasses. A total of 102 beef carcasses were used to measure the average temperature of the front surface, rear surface, LT and the whole carcass with IRT, and the temperature and pH of the LT. The Random Forest machine learning algorithm was optimized for prediction. It was possible use IRT to predict temperature of longissimus thoracis bovine with R<sup>2</sup> values ranging 0.06 to 0.78 and MAE 1.12 to 1.67. For initial temperature was R<sup>2</sup> of 0.06 and ultimate temperature with R<sup>2</sup> values 0.26 and 0.17. The inclusion of hot carcass weight parameter enhanced to the prediction ultimate temperature with the image obtained of hot carcass with an R<sup>2</sup> of 0.68 and chilled carcass of 0.78. The prediction of muscle pH with thermal images showed R<sup>2</sup> values ranging from 0.26 to 0.82 and MAE 0.10 a 0.82. The combination of hot carcass weight contributed to predicted muscle ultimate pH in the carcass with R<sup>2</sup> value of 0.70. It is concluded that it is possible use thermographic images as a tool to predict the initial and ultimate pH and

temperature longissimus thoracis of beef carcasses. When combined with hot carcass weight parameter may exhibit even greater efficiency in predicting ultimate pH and temperature in LT of carcass.

**Keywords:** Accuracy, Beef, Machine learning, Thermal image.

## 1. Introduction

The evaluation of carcass temperature and pH are decisive for meat quality attributes, such as color, tenderness, and flavor, as they influence the kinetics of biochemical reactions and the conversion of muscle tissue into meat (Savell, Mueller & Baird, 2005). Slow chilling of carcasses affects enzymes such as phosphorylase, which are involved in the functioning of the glycolytic pathway, the accumulation of lactate, and the decline in pH. Additionally, it influences the proliferation of pathogenic and spoilage microorganisms (Mohrhauser, Lonergan, Huff-Lonergan, Underwood & Weaver, 2014). On the other hand, accelerated chilling mitigates microbial proliferation, but can slow reactions of the glycolytic pathway, cause sarcomere shortening and reduce meat tenderness (Marsh, 1977).

In this context, the European Union establishes a minimum ultimate temperature of 7°C from the cold room and a maximum ultimate pH of 5.8 for beef carcasses (DIPOA-DSA/SDA Joint Circular No. 8/2023). As well as Savell, Mueller and Baird (2005) recommend if the pH is higher than 6.2, then the temperature of the carcass must be kept above 10°C. Therefore, to meet the market, the meat industry needs to monitor the temperature and pH of the bovine carcass. However, traditional monitoring is laborious, as it's done manually on Longissimus thoracis (LT), using a thermometer and a pH meter. Furthermore, it's necessary handling on carcass, which contributes to contamination of the final product.

As alternative to automate processes, new technologies have been implemented in slaughterhouses, with emphasis on the use of images, for their remote monitoring capacity and provide big data. (Echegaray et al. 2022). The use of infrared thermography (IRT) cameras has been studied in livestock farming since the last century (Hurnik, Webster & DeBoer, 1985), as these devices can capture infrared radiation proportional to body temperature (Warriss, Pope,

Brown, Wilkins & Knowles, 2006). The technique allows measure the surface temperature without contact, as showed by Wu, Liang, Wang, Wu and Sun (2022) being IRT compared to traditional methods is an alternative for large-scale measurement and evaluation of meat quality.

Cuthbertson et al. (2020) pointed that the body temperature data from cattle obtained by IRT are indicator of changes in the temperament of animals and it's a potential predictor of carcass quality. In addition, Costa et al. (2007) evaluated the implementation of IRT on the pig slaughter line, and although they found no relationship between surface temperature and pork quality, they indicated that the technique is suitable for other purposes on the production line, such as selecting legs for processing. For predicting the pH of beef, Savoia et al. (2020) obtained satisfactory results using infrared spectrometers, which, due to their similarity to IRT, may indicate its potential for predicting pH. Recently, Ferreira et al. (2024) showed that it's possible use ocular IRT as a tool to predicted ultimate pH in bovine carcass.

However, the use of thermographic images and machine learning (ML) to predict and evaluate carcasses remains unexplored. The thermographic image data associated with ML (artificial intelligence tool) enables regression and classification. Among the ML algorithms, Random Forest (RF) show attention because easy programming, requires few adjustments and work well for high-variance and multicollinearity (Hastie, Tibshirani & Friedman, 2009). For predictions, RF weighting the predictor variables according to the importance, the number of variables in each split (*mtry*) and number of trees (*ntree*) are the main parameters to be adjusted. After, relies on the construction of several random decision trees, that reduces the variance of the prediction and provides a final prediction from the average of the forest (Genuer, & Poggi, 2020), and ML performance could be evaluated using coefficient of determination ( $R^2$ ), the mean absolute error (MAE), the root mean square error (RMSE) metrics.

In view of the potential of IRT and artificial intelligence tools, there are the lack of studies associated these techniques for predicted parameters on the bovine carcasses. Therefore, the objective of study was evaluated hot or chilled bovine carcass infrared thermography data using RF to predict initial or ultimate temperature and pH of *Longissimus thoracis* of bovine carcasses.

## 2. Materials and Methods

### 2.1. Data collection

The experiment was conducted by collecting data from the carcasses of 62 F1 Red Angus X Nelore cattle and 40 Nelore cattle at approximately 14 months of age and slaughtered at the Frigorífico Escola of the Federal University of Viçosa (UFV) between 2021 and 2022.

After the stages of humane slaughter, the left ½ carcasses were weighed, and the initial pH (pH.0h) and temperature (T<sup>0</sup>.0h) were collected by gold standard. The temperature was measured using a meat thermometer at the thirteenth rib in the *Longissimus thoracis* at a depth of 2.5 cm. The pH was obtained using a Hanna model HI99163 portable meter at the same location. At the same time, the surface lateral views of ½ hot carcasses were imaged using a Flir C5 thermographic camera, with an emissivity of 0.95, positioned 317 cm from the carcass and 140 cm from the ground using a tripod.

In accordance with Brazilian legislation, the carcasses underwent sanitary maturation in a cold room for 24 hours at 4°C. The ultimate pH (pH.24h) and temperature (T<sup>0</sup>.24h) were recorded by the gold standard, and surface image of chilled carcass was taken, following the same methodology.

### 2.2. Image processing

The hot and chilled carcass images were uploaded after data collection (Figure 1a). We obtained the images in JPG and pixel matrix in absorbance and pre-processed them using the Thermimage package in R 4.1.2 software (R Core Team. 2021) to extract the thermographic features. The raw2Temp function was used to convert absorbance (JPG) into temperature (°C), with a 160 × 120pixel resolution.

ImageJ software was then used to extract the features, which are the average surface temperatures of the areas of interest. These were obtained by manually marking out the region of interest, as shown in Figure 1b. By circling an area, the software allows the average temperature of the pixels contained in the region to be obtained. The average temperature of the Longissimus (LT) was

obtained in the region of a 6 cm radius circle positioned in the region of this muscle. The average front temperature (FT) and average hind temperature (HT) temperatures were obtained by delimiting the front and hind regions of the carcass, respectively. Finally, the average carcass temperature (AT) was extracted by delimiting the entire area of the carcass. For hot carcass features used 0h and chilled 24h. A description of the data set is shown in Table 1.

### **2.3. Statistical analysis**

Pearson's correlation coefficient was estimated to explore the relationship between pH and temperature measured by the traditional method, hot carcass weight (HCW) and the attributes extracted from the thermographic images, at a 5% significance level. The correlations were classified as low (0.00 - 0.29), moderate (0.30 - 0.59) and high (0.60 - 0.99) (Callegari-Jacques, 2003).

The Random Forest (RF) algorithm (Hastie, Tibshirani & Friedman, 2009) was used to build the initial and ultimate pH and temperature prediction models; initial temperature ( $T^{\circ}.0h$ ) of Longissimus prediction with the features of the hot carcass images, ultimate temperature ( $T^{\circ}.24h$ ) of Longissimus prediction with the features of the chilled carcass images, ultimate temperature ( $T^{\circ}.24h$ ) of Longissimus prediction with the features of the chilled carcass images, and initial pH (pH.0h) of Longissimus prediction with the features of the hot carcass images, ultimate pH of Longissimus prediction with the features of the hot carcass images and ultimate pH (pH.24h) prediction (pH.24h) of Longissimus with the features of the chilled carcass images. In addition, these same models were re-run adding HCW to the predictor variables.

The database was randomly divided into 70% for training and 30% for testing. The model was optimized based on the hyperparameters (Mtry, ntree and nodesize) extracted by reducing the root-mean-square error (RMSE) using the cross-validation method (5-folds), and the importance of the variables in the final model was calculated. The relative importance of each variable in the model's performance is provided by R and corresponds to the extent to which the tree nodes use the feature (Géron, 2022).

We determined that if a variable represents more than 60% of the importance in the model, a simple linear regression will be fitted using the least

squares method, which will have its fit assessed by the coefficient of determination ( $R^2$ ). The regression can be described as:

$$y = \alpha + \beta x$$

The predictive performance of the final models was assessed by the  $R^2$ , RMSE and mean absolute error (MAE) obtained by equations 1, 2 and 3, respectively.

$$(1) \quad R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

(2)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

(3)

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Where  $n$  is the number of samples,  $y_i$  is the observed value,  $\bar{y}$  is the average of the observations,  $\hat{y}_i$  is the predicted value of the  $i$ th observation.

### 3. Results and Discussion

The correlations between the variables measured traditionally and those extracted from the images were calculated (Table 2) to visualize the association between them and to aid interpretation of the predicted results. The metrics extracted from the images of the hot carcass were less correlated with the traditional measurements than those of the chilled carcass metrics. Of these, only LT.0h was significant, correlating with ultimate (0.265) and final temperature (0.223).

However, all the metrics from the chilled carcass images correlated with the traditional measurements at 24 h and HCW. Ultimate pH and temperature of Longissimus on the bovine carcass had moderate correlations with the thermographic variables, with LT<sup>0</sup>.24h having the highest values (pH.24h = 0.328 and T<sup>0</sup>.24h = 0.498). The LT metric was taken from the region of the carcass corresponding to where pH and temperature were measured, which may explain

its better performance. The correlation values indicate that the higher the temperature obtained from the image, the higher the pH.24h and T°.24h from the traditional method.

HCW showed a high positive correlation with ultimate temperature of Longissimus on the bovine carcass (0.754), which is consistent with the literature and suggests that this variable is a determining factor in the cooling rate of carcasses. Hippe, Field, Ray, and Russell (1991) found that light, lean carcasses cool faster than heavier, fatter carcasses because of the thermal protection of the fat and the greater surface area of heavier carcasses slow down cooling.

Horcada, Juárez, Valera and Bartolomé (2019) reported that heavier carcasses resulted in a higher ultimate pH. However, in our study, no significant relationship was found between HCW and ultimate pH. According to the carcass weight classification used by Horcada, Juárez, Valera and Bartolomé (2019), the carcasses used would be considered light. In this category, they found a positive correlation between pH and pre-slaughter IRT, indicating that the higher the animal's temperature, the higher the ultimate pH. This was not the case in our study because pH.24h and T°.0h did not correlate. This comparison can be made because the pre-slaughter animal temperature is proportional to that of the carcass immediately after slaughter.

### **3.1. Temperature prediction**

Because of the importance of carcass cooling, it needs to be monitored efficiently, so predicting the temperature of the carcasses using thermographic images, as well as allowing non-contact visual assessment on the processing lines (Echegaray et al., 2022), reducing contamination and allowing cooling conditions to be adapted to the demands of the carcass and market requirements.

The predictions of initial (T°.0h) and final (T°.24h) temperature of Longissimus on the bovine carcass from the metrics extracted from the thermographic image of hot carcass were not accurate ( $R^2 < 0.2$ , RMSE  $< 2.0^\circ\text{C}$ , MAE  $< 1.7^\circ\text{C}$ ) (Figure 2 a and c). All the variables included in the models were significant for the predictions. The most important variables in both models were the same. The Longissimus region stood out (b = 34%, d = 32%) because it is where the temperature is traditionally measured. This was followed by AT (b =

27%,  $d = 25\%$ ), FT ( $b = 20\%$ ,  $d = 23\%$ ), and HT ( $b = 18\%$ ,  $d = 19\%$ ) (Figure 2 b and d).

The  $R^2$  numerically expresses the dispersion of the data around a straight line (Tedeschi, 2006).  $R^2 < 0.2$  illustrates dispersed data (Figure 2), indicating that the model explained less than 20% of the total variation. Thus, the prediction is inaccurate. Predictive accuracy can be obtained using error metrics, and in these models, the errors were less than  $2^\circ\text{C}$ , equivalent to 5.68% of the average initial temperature ( $T^{0.0h}$ ) and 24.1% of the average ultimate temperature ( $T^{0.24h}$ ) (Table 1).

The error obtained in predicting the  $T^{0.0h}$  was low in relation to the average, and the model can be used because a 5% variation in predicting the  $T^{0.0h}$  does not compromise the monitoring quality. However, we do not recommend the model for predicting the  $T^{0.24h}$  because 24% is a high variation, especially for the final temperature. Failure to adapt the temperature to the requirements of the export market could lead to the carcass being disqualified for export. In addition, the temperature after cooling plays an important role in microbiological control, especially in the marketing of chilled meat.

The prediction of ultimate temperature ( $T^{0.24h}$ ) of Longissimus on the bovine carcass using chilled carcass surface images was also inaccurate ( $R^2 = 0.26$ , MAE = 1.45, RMSE = 1.8) (Figure 2 e). Unlike the models that used hot carcass images as predictors, in this one, the variable with the most significant contribution was the forequarter temperature (31%). Compared to others, this region had the lowest average temperature (Table 1), which can be explained by the lower muscularity of the area, which contributes to faster cooling. Therefore, the coldest region of the carcass was the best predictor of  $T^{0.24h}$ . The other variables, HT, LT, and AT contributed 27%, 24%, and 18%, respectively. This model, like the others shown in Figure 2, illustrated scattered data, and only 26% of the variability in the data was explained by it. The error, although smaller, is more than 17% in relation to the average  $T^{0.24h}$ . Therefore, due to the low precision, low accuracy, and the importance of  $T^{0.24h}$  for meat quality, we do not recommend using this model.

To improve the accuracy and precision of the models, we included hot carcass weight (HCW) as a variable, and it became the most important predictive variable, even though it did not contribute to improving the model's performance, as shown in graph (a) (Figure 3). When  $T^{0.0h}$  was predicted using the features of the surface thermal hot carcass images and HCW, there was no improvement in precision or accuracy ( $R^2 = 0.06$ ,  $RMSE = 2.13$ ,  $MAE = 1.55$ ) (Figure 3 a). The relative error remained at approximately 5%, suggesting that this model can be used. HCW and LT closely contributed to performance at 28% and 27%, while AT, FT, and HT had 23%, 13%, and 9%, respectively. Compared to the other models in which the weight had an importance above 60%, its contribution was lower in our model. Consequently, the performance of this forecast was lower than others. We believe that HWC did not improve the performance of the  $T^{0.0h}$  predictive model, as no reports in the literature indicate that HCW influences initial carcass temperature. However, as previously mentioned, HCW controls the cooling rate, and the high correlation between it and  $T^{0.24h}$  confirms this relationship (Table 2).

The prediction of ultimate carcass temperature using thermographic features and HCW was accurate. The model performed better with the images taken at 24 h ( $R^2 = 0.78$ ,  $MAE = 1.02$ , and  $RMSE = 1.22$ ) (Figure 3 e). Dangeti (2017) stated that algorithms with  $R^2$  above 0.70 show good fit and accuracy. In addition, the relative error was 10% in relation to the average  $T^{0.24h}$ . It is therefore possible to measure the  $T^{0.24h}$  accurately and precisely from thermographic images. With the data from the images at 0 h, ( $R^2 = 0.68$ ,  $MAE = 1.12$  and  $RMSE = 1.34$ ) (Figure 3 c), the results were also considered satisfactory due to the complexity of predicting the temperature after cooling based on the images and HCW. Despite the lower  $R^2$  compared to the E model (Figure 3), the error was only  $0.1^\circ\text{C}$  higher, which we consider low.

The possibility of predicting the ultimate LT temperature with the hot carcass images is a great advantage for slaughterhouses. Only with these images and the HCW would it be possible to obtain the initial and final temperatures and, therefore, the individual cooling rate. Dmjisa et al. (2022) argued that segregating the carcasses by size and fat for colling could result in uniformity in meat quality, as it would mitigate the different cooling rates.

In the T<sup>o</sup>.24h prediction models, the variable that contributed most to the predictions was HCW (d = 60% and f = 74%), followed by LT (d = 11% and f = 8%), AT (d = 8% and f = 8%), HT (d = 10% and f = 6%), and FT (d = 10% and f = 5%) (Figure 3). As mentioned above, there is a proportional relationship between the surface area and the heat dissipation rate of a carcass, which justifies the more significant contribution of HCW to the modeling.

As a result of the high relative importance of HCW (greater than 60%) for predicting T<sup>o</sup>.24h, we fitted a simple linear regression (Graphic 1), where HCW was used to predict T<sup>o</sup>.24h values. The R<sup>2</sup> obtained indicates that 57% of the variability in T<sup>o</sup>.24h can be explained by the model.

Thermography is considered a valuable tool for predicting poor meat quality in cattle (Cuthbertson et al., 2020). Thus, this technique has the potential for implementation in slaughterhouses because the dataset is larger, which would contribute to improved performance of prediction models. In addition, a preliminary study by Hite, Blair, Underwood, and Grubbs (2020) showed that a FLIR camera could capture images of carcasses during the slaughterhouse process and assess their cooling. Further studies should be conducted to reconcile thermography and carcass weighing with the Random Forest algorithm in slaughterhouse industry environments to modernize traditionally invasive and time-consuming monitoring.

### **3.2. pH prediction**

The prediction of initial pH (pH.0h) of Longissimus on the bovine carcass using hot carcass thermographic images was precise (R<sup>2</sup> = 0.82, MAE = 0.11, RMSE = 0.13) (Figure 4 a). The predictor variables contributed similarly, which indicates the importance of all of them for the performance obtained. AM stood out with 28%, followed by LT and FT at 24% and HT at 23% (Figure 4 b). Using the same evaluation criteria as in Section 3.1, the model showed excellent predictive performance, explaining 82% of the total variation and high accuracy because the error was less than 2% in relation to the average pH.0h (Table 1). Hamoen, Vollebregt, and Van Der Sman (2013), in their pH predictive model based on metabolism, obtained a relative error of 2.5%. De Marchi, Penasa,

Cecchinato, and Bittante (2013) reinforced the ability of visible and near-infrared (vis–NIR) in beef cuts to predict pH with a relative error of 2.49%.

However, the prediction of the ultimate pH (pH.24h) of Longissimus on the bovine carcass did not have good precision and accuracy, with the worst performance using surface thermal images of hot carcass ( $R^2 = 0.26$ , MAE = 0.82, RMSE = 0.87) (Figure 4 c). In addition to the high dispersion of the data around the straight line, the error was greater than 14% in relation to the average pH.24h (Table 1). Thus, we do not recommend using it. In this case, the contributions of the variables were also close, with percentages of 29%, 27%, 23%, and 21% for LT, FT, HT, and AT, respectively (Figure 4 d). The prediction of the final pH with the features of the images at 24 h, despite its low accuracy ( $R^2 = 0.33$ , MAE = 0.21, RMSE = 0.32) (Figure 4 e), had good accuracy, with a 4.5% error in relation to the average pH.24h (Table 1). AT and FT had 32% contributions to the model, and HT and LT had 19% and 16% contributions, respectively (Figure 4 f).

We included HCW as a predictor variable based on its relationship with the cooling rate and pH decrease to improve the model performance. As previously suggested, increased carcass mass and fat finishing imply slower cooling, accelerating the reduction in pH (Mohrhauser, Lonergan, Huff-Lonergan, Underwood & Weaver, 2014). Moreover, heavier carcasses have a lower initial pH (Djimisa et al., 2022). The prediction of pH.0h was accurate ( $R^2 = 0.81$ ) with subtle improvements in the accuracy, with reductions in the MAE and RMSE from 0.11 and 0.14 to 0.10 and 0.12, respectively (Figure 5 a). Weight was the most important variable, with a 40% contribution, followed by AT, HT, LT, and FT, with 18%, 14%, 14%, and 13%, respectively (Figure 5 b). Owing to the high explanatory power of the model and a relative error of less than 2%, the pH.0h predictions are considered accurate. Therefore, the technique has the potential for implementation as a replacement for traditional pH measurement.

In contrast to the results obtained in the prediction of temperature (Figures 2 and 3), the models for predicting initial pH at 0 h had the best accuracy ( $R^2 > 0.80$ ), with and without the inclusion of HCW (Figures 4 and 5). This result indicates the better efficiency of the technique in hot carcasses. The prediction of pH.24h with the images at 0 h had better precision and accuracy when HCW was added to the model ( $R^2 = 0.70$ , MAE = 0.19, RMSE = 0.24) (Figure 5 c), which

became the most important variable, with a 28% contribution. The other variables maintained their order of importance in the model without the HCW, where LT is the main contributor, at 20%, followed by FT, HT, and AT, with 19%, 19%, and 15%, respectively (Figure 5 d). The error relative to the average pH.24h is 3.6%, and we believe that owing to the complexity of predicting the final pH based only on thermographic images and the HCW, the model had excellent predictive performance. This indicates the technique's potential for implementation in slaughterhouses, where the database would be expanded, and the model's error would be reduced.

The models shown in Figure 5 have improved performance owing to the inclusion of the HCW. However, the model that predicted pH.24h with the images at 24 h remained inaccurate with HCW included ( $R^2 = 0.36$ , MAE = 0.21, RMSE = 0.32) (Figure 5 e). This does not affect our recommendations regarding the technique's potential because the previous model (Figure 5 c) predicted pH.24h. However, it does reinforce our theory about the superiority of predicting pH using images of hot carcasses. Regarding the line in slaughterhouses, predicting pH at 24 h with data from images taken at 0 h is more valuable than with images at 24 h because it is possible to predict the final and initial pH only with the 0 h images and the HCW (Figure 5 a and c).

Other studies have sought to explore technologies for monitoring pH, such as Dixit, Al-Sarayreh, Craigie and Reis (2021) who used hyperspectral images of meat from different species and muscles. They were successful in finding a global model for predicting meat pH but encourage more studies to be carried out on other muscle groups and species. Hamoen, Vollebregt and Van Der Sman (2013) with the aid of a pH sensor adapted a model describing the biochemistry of post-mortem meat with temperature data to predict the final pH and concluded that it is a reliable tool for assessing meat quality. We believe that thermographic cameras are a viable alternative for slaughterhouses due to their portability, easy adaptation to slaughter lines and low cost (Mohrhauser, Lonergan, Huff-Lonergan, Underwood & Weaver, 2014).

#### **4. Conclusion**

It is possible to predict the ultimate temperature and pH of *Longissimus thoracis* with hot and chilled beef carcasses using thermographic image features and the hot carcass weight. However, its necessary to improve predictions of initial temperature with IRT associated or not with the hot carcass weight. We recommend validating these results with more data to assess the feasibility of large-scale slaughterhouse use and its adaptation to the environment.

### **Conflict of interest**

The authors declare no conflict of interest.

### **Funding**

This work was supported by Fundação de Amparo à Pesquisa de Minas Gerais (FAPEMIG) APQ-01928-22 and Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

### **References**

- Callegari-Jacques, SM (2003). *Bioestatística: Princípios e Aplicações*. Porto Alegre: Artmed.
- DIPOA-DSA/SDA Joint Circular No. 8/2023. (2023, 4 de agosto). GOV.BR. [https://www.gov.br/agricultura/pt-br/assuntos/sanidade-animal-e-vegetal/saude-animal/cgtqa/t-inter/exportacao/epec/OfcioCircularConjuntoDIPOADSASDAN8\\_2023carnebovUE.pdf](https://www.gov.br/agricultura/pt-br/assuntos/sanidade-animal-e-vegetal/saude-animal/cgtqa/t-inter/exportacao/epec/OfcioCircularConjuntoDIPOADSASDAN8_2023carnebovUE.pdf) Acess in: 03/11/2023
- Costa, N., Stelletta, C., Cannizzo, C., Giancesella, M., Lo Fiego, P., & Morgante, M. (2007). The use of thermography on the slaughter-line for the assessment of pork and raw ham quality. *Italian journal of animal science*, 6(sup1), 704-706. <https://doi.org/10.4081/ijas.2007.1s.704>
- Cuthbertson, H., Tarr, G., Loudon, K., Lomax, S., White, P., McGreevy, P., & González, L. A. (2020). Using infrared thermography on farm of origin to predict meat quality and physiological response in cattle (*Bos Taurus*) exposed to transport and marketing. *Meat science*, 169, 108173. <https://doi.org/10.1016/j.meatsci.2020.108173>
- Dangeti, P. (2017). *Statistics for machine learning*. Packt Publishing Ltd.
- De Marchi, M., Penasa, M., Cecchinato, A., & Bittante, G. (2013). The relevance of different near infrared technologies and sample treatments for predicting meat quality traits in commercial beef cuts. *Meat Science*, 93(2), 329-335. <https://doi.org/10.1016/j.meatsci.2012.09.013>
- Dixit, Y., Al-Sarayreh, M., Craigie, C. R., & Reis, M. M. (2021). A global calibration model for prediction of intramuscular fat and pH in red meat using hyperspectral imaging. *Meat Science*, 181, 108405. <https://doi.org/10.1016/j.meatsci.2020.108405>
- Djimisa, B. A. & N. Nair, M. & Hess, A. M. & Belk, K. E. & Woerner, D. R., (2022) "The Impact of Carcass Size, Chilling Conditions, and Electrical

Stimulation on Beef Postmortem Temperature and pH Decline", *Meat and Muscle Biology* 6(1): 13893, 1-16. <https://doi.org/10.22175/mmb.13893>

Echegaray, N., Hassoun, A., Jagtap, S., Tetteh-Caesar, M., Kumar, M., Tomasevic, I., & Lorenzo, J. M. (2022). Meat 4.0: Principles and applications of Industry 4.0 technologies in the meat industry. *Applied Sciences*, 12(14), 6986. <https://doi.org/10.3390/app12146986>

Ferreira, G. A., Barro, A. G., Bueno, C. E. M., Terto, D. K., Dos Santos, É. R., Ogawa, N. N., ... & Bridi, A. M. (2024). Non-invasive meat quality assessment: Exploring the potential of ocular infrared thermography to predict ultimate pH in Nellore beef cattle. *Meat Science*, 213, 109483. <https://doi.org/10.1016/j.meatsci.2024.109483>

Genuer, R., & Poggi, J. M. (2020). *Random forests* (pp. 33-55). Springer International Publishing. [https://doi.org/10.1007/978-3-030-56485-8\\_3](https://doi.org/10.1007/978-3-030-56485-8_3)

Géron, A. (2022). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. " O'Reilly Media, Inc."

Hamoen, J. R., Vollebregt, H. M., & Van Der Sman, R. G. M. (2013). Prediction of the time evolution of pH in meat. *Food chemistry*, 141(3), 2363-2372. <https://doi.org/10.1016/j.foodchem.2013.04.127>

Hastie, T., Tibshirani, R., Friedman, J. H., & Friedman, J. H. (2009). The elements of statistical learning: data mining, inference, and prediction (Vol. 2, pp. 1-758). New York: springer.

Hippe, C. L., Field, R. A., Ray, B., & Russell, W. C. (1991). Effect of spray-chilling on quality of beef from lean and fatter carcasses. *Journal of animal science*, 69(1), 178-183. <https://doi.org/10.2527/1991.691178x>

Hite, L. M., Blair, A. D., Underwood, K. R., & Grubbs, J. K. (2020). Investigation on the Use of a FLIR (Forward Looking Infrared) Camera to Detect Relationships Between Internal and Surface Temperatures of Beef Carcasses During Chilling. Investigation on the Use of a FLIR (Forward Looking Infrared) Camera to Detect Relationships Between Internal and Surface Temperatures of Beef Carcasses During Chilling (sdstate.edu). Access in: 10/11/2023

Horcada, A., Juárez, M., Valera, M., & Bartolomé, E. (2019). Using infrared ocular thermography as a tool to predict meat quality from lean cattle breeds prior to slaughter: Exploratory trial. *Spanish Journal of Agricultural Research*, 17(4), e06SC01-e06SC01. <https://doi.org/10.5424/sjar/2019174-15487>

Hurnik, J. F., Webster, A. B., & DeBoer, S. (1985). An investigation of skin temperature differentials in relation to estrus in dairy cattle using a thermal infrared scanning technique. *Journal of Animal Science*, 61(5), 1095-1102. <https://doi.org/10.2527/jas1985.6151095x>

Marsh, B. B. (1977). The Basis of Quality in Muscle Foods The basis of tenderness in muscle foods. *Journal of Food Science*, 42(2), 295-297. <https://doi.org/10.1111/j.1365-2621.1977.tb01485.x>

Marsh, B. B., Lochner, J. V., Takahashi, G., & Kragness, D. D. (1981). Effects of early post-mortem pH and temperature on beef tenderness. *Meat science*, 5(6), 479-483. [https://doi.org/10.1016/0309-1740\(81\)90046-2](https://doi.org/10.1016/0309-1740(81)90046-2)

Mohrhauser, D. A., Lonergan, S. M., Huff-Lonergan, E., Underwood, K. R., & Weaver, A. D. (2014). Calpain-1 activity in bovine muscle is primarily influenced by temperature, not pH decline. *Journal of Animal Science*, 92(3), 1261-1270. <https://doi.org/10.2527/jas.2013-7270>


Savell, J. W., Mueller, S. L., & Baird, B. E. (2005). The chilling of carcasses. *Meat science*, 70(3), 449-459. <https://doi.org/10.1016/j.meatsci.2004.06.027>

Savoia, S., Albera, A., Brugiapaglia, A., Di Stasio, L., Ferragina, A., Cecchinato, A., & Bittante, G. (2020). Prediction of meat quality traits in the abattoir using portable and hand-held near-infrared spectrometers. *Meat science*, 161, 108017. <https://doi.org/10.1016/j.meatsci.2019.108017>

Tedeschi, L. O. (2006). Assessment of the adequacy of mathematical models. *Agricultural systems*, 89(2-3), 225-247. <https://doi.org/10.1016/j.agsy.2005.11.004>

Warriss, P. D., Pope, S. J., Brown, S. N., Wilkins, L. J., & Knowles, T. G. (2006). Estimating the body temperature of groups of pigs by thermal imaging. *Veterinary Record*, 158(10), 331-334. <https://doi.org/10.1136/vr.158.10.331>

Wu, X., Liang, X., Wang, Y., Wu, B., & Sun, J. (2022). Non-destructive techniques for the analysis and evaluation of meat quality and safety: a review. *Foods*, 11(22), 3713. <https://doi.org/10.3390/foods11223713>



**Figure 1:** (A) Thermographic image of ½ of the left carcass at 0h; (B) sketch of the delimitations drawn on the pre-processed image in ImageJ software. AT: Average thermographic temperature of the carcass (°C); LT: Thermographic temperature of the circle of the carcass (°C); HT: Thermographic temperature of the hind of the carcass (°C); FT: Thermographic temperature of the front of the carcass(°C).

**Table 1.** Descriptive statistics of the variables<sup>1</sup>

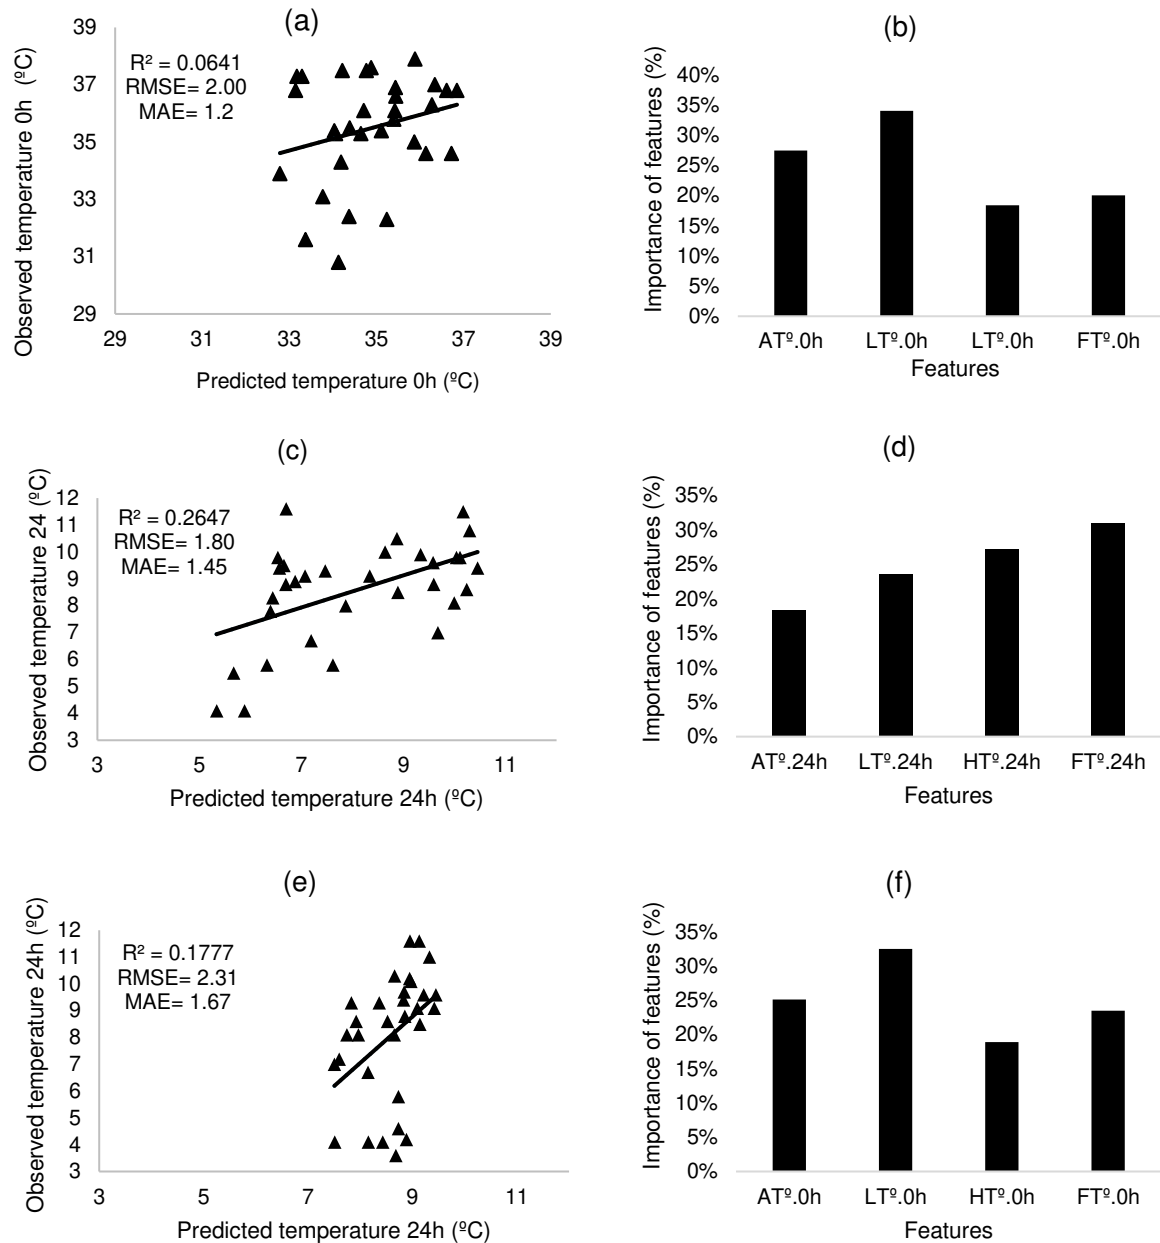
	<b>Mín.</b>	<b>Average</b>	<b>Máy.</b>	<b>sd<sup>2</sup></b>
<b>HCW</b>	74.40	123.50	171.80	22.75
<b>pH.0h</b>	5.92	6.54	7.07	0.24
<b>T°.0h</b>	29.30	35.10	39.90	2.11
<b>T°.24h.</b>	3.60	8.29	11.60	2.04
<b>pH.24h</b>	5.33	5.79	6.90	0.56
<b>AT°.0h</b>	16.20	24.70	29.44	1.92
<b>LT°.0h</b>	17.99	24.41	29.47	1.94
<b>BT°.0h</b>	19.18	25.56	29.62	1.81
<b>FT°.0h</b>	16.37	24.56	29.62	1.93
<b>AT°.24h</b>	2.31	8.42	12.12	2.11
<b>LT°.24h</b>	12.12	7.48	11.30	2.33
<b>BT°.24h</b>	4.65	10.24	13.82	2.07
<b>FT°.24h</b>	2.11	8.07	12.13	2.14

<sup>1</sup> HCW: hot carcass weight (kg) at 0h; pH.0h: carcass pH at 0h; T°.0h: carcass temperature at 0h (°C); T°.24h: carcass temperature at 24h (°C); pH.24h: carcass pH at 24h; AT°.0h: Average thermographic temperature of the carcass at 0h (°C); LT°.0h: Thermographic temperature of the circle of the carcass at 0h (°C); HT°.0h: Thermographic temperature of the hind of the carcass at 0h (°C); FT°.0 h: Thermographic temperature of the front of the carcass at 0h (°C); AT°.24h: Average thermographic temperature of the carcass at 24h (°C); LT°.24h: Thermographic temperature of the circle of the carcass at 24h (°C); HT°.24h: Thermographic temperature of the hind of the carcass at 24h (°C); FT°.24h: Thermographic temperature of the front of the carcass at 24h (°C). <sup>2</sup>Standard Deviation.

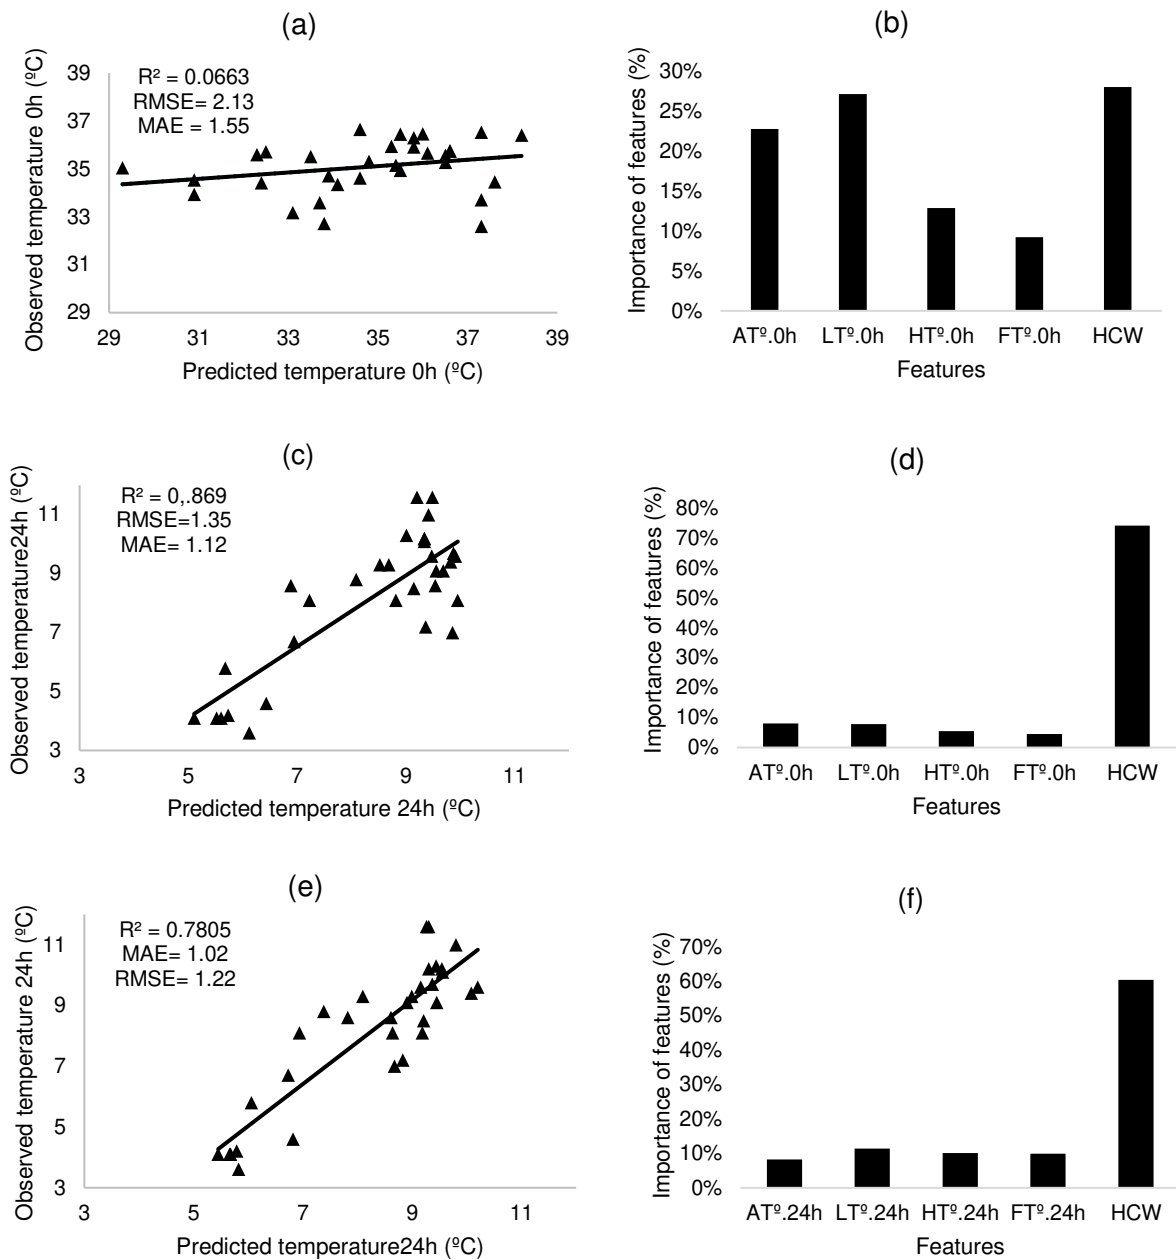
**Table 2.** Pearson's correlation coefficients between features of surface image and initial and ultimate temperature and pH.

	<b>HCW<sup>1</sup></b>												
<b>pH.0h</b>	0.213*	<b>pH.0h</b>											
<b>T<sup>o</sup>.0h</b>	0.335*	0.202*	<b>T<sup>o</sup>.0h</b>										
<b>T<sup>o</sup>.24h</b>	0.754*	0.221*	0.465*	<b>T<sup>o</sup>.24h</b>									
<b>pH.24h</b>	0.179	0.200*	0.132	0.220*	<b>pH.24h</b>								
<b>AT<sup>o</sup>.0h</b>	0.027	-0.021	0.150	0.172	0.146	<b>AT<sup>o</sup>.0h</b>							
<b>LT<sup>o</sup>.0h</b>	0.102	0.122	0.265*	0.223*	0.134	0.716*	<b>LT<sup>o</sup>.0h</b>						
<b>BT<sup>o</sup>.0h</b>	-0.020	0.044	0.075	0.074	0.094	0.755*	0.828*	<b>BT<sup>o</sup>.0h</b>					
<b>FT<sup>o</sup>.0h</b>	0.049	0.039	0.111	0.103	0.110	0.781*	0.855*	0.902*	<b>FT<sup>o</sup>.0h</b>				
<b>AT<sup>o</sup>.24h</b>	0.442*	0.154	0.231	0.455*	0.327*	0.037	0.170	0.032	0.050	<b>AT<sup>o</sup>.24h</b>			
<b>LT<sup>o</sup>.24h</b>	0.469*	0.188	0.271	0.498*	0.328*	0.050	0.188	0.034	0.060	0.986*	<b>LT<sup>o</sup>.24h</b>		
<b>BT<sup>o</sup>.24h</b>	0.363*	0.099	0.159	0.373*	0.312*	0.064	0.153	0.038	0.052	0.976*	0.940*	<b>BT<sup>o</sup>.24h</b>	
<b>FT<sup>o</sup>.24h</b>	0.493*	0.169	0.256	0.489*	0.320*	0.040	0.172	0.021	0.045	0.994*	0.980*	0.965*	<b>FT<sup>o</sup>.24h</b>

<sup>1</sup> HCW: hot carcass weight (kg); pH.0h: carcass pH at 0h; T<sup>o</sup>.0h: carcass temperature at 0h (°C); T<sup>o</sup>.24h: carcass temperature at 24h (°C); pH.24h: carcass pH at 24h; AT<sup>o</sup>.0 h: Average thermographic temperature of the carcass at 0h (°C); LT<sup>o</sup>.0h: Thermographic temperature of the circle of the carcass at 0h (°C); HT<sup>o</sup>.0h: Thermographic temperature of the hind of the carcass at 0h (°C); FT<sup>o</sup>.0 h: Thermographic temperature of the front of the carcass at 0h (°C); AT<sup>o</sup>.24h: Average thermographic temperature of the carcass at 24h (°C); LT<sup>o</sup>.24h: Thermographic temperature of the circle of the carcass at 24h (°C); HT<sup>o</sup>.24h: Thermographic temperature of the hind of the carcass at 24h (°C); FT<sup>o</sup>.24h: Thermographic temperature of the front of the carcass at 24h (°C). \*p-value < 0.05.



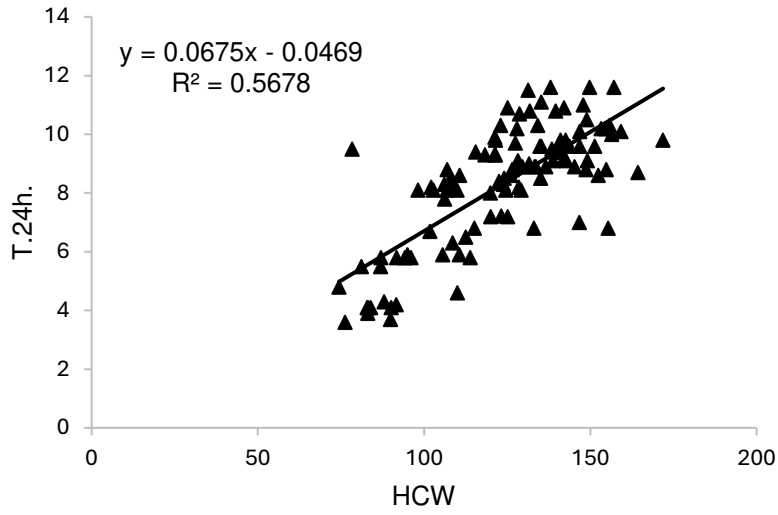
**Figure 2:** Temperature prediction using features<sup>1</sup> from thermographic images and the importance of the features in the corresponding models (b,d,f). a: Temperature prediction at 0h using data from thermographic images at 0h. c: Temperature prediction at 24h using data from thermographic images at 0h. e: Temperature prediction at 24h using data from thermographic images at 24h. <sup>1</sup>AT<sup>0</sup>.0h: Average thermographic temperature of the carcass at 0h (°C); LT<sup>0</sup>.0h: Thermographic temperature of the Longissimus of the carcass at 0h (°C); HT<sup>0</sup>.0h: Thermographic temperature of the hind of the carcass at 0h (°C); FT<sup>0</sup>.0h: Thermographic temperature of the front of the carcass at 0h (°C); AT<sup>0</sup>.24h: Average thermographic temperature of the carcass at 24h (°C); LT<sup>0</sup>.24h: Thermographic temperature of the circle of the carcass at 24h (°C); HT<sup>0</sup>.24h: Thermographic temperature of the hind of the carcass at 24h (°C); FT<sup>0</sup>.24h: Thermographic temperature of the front of the carcass at 24h (°C).

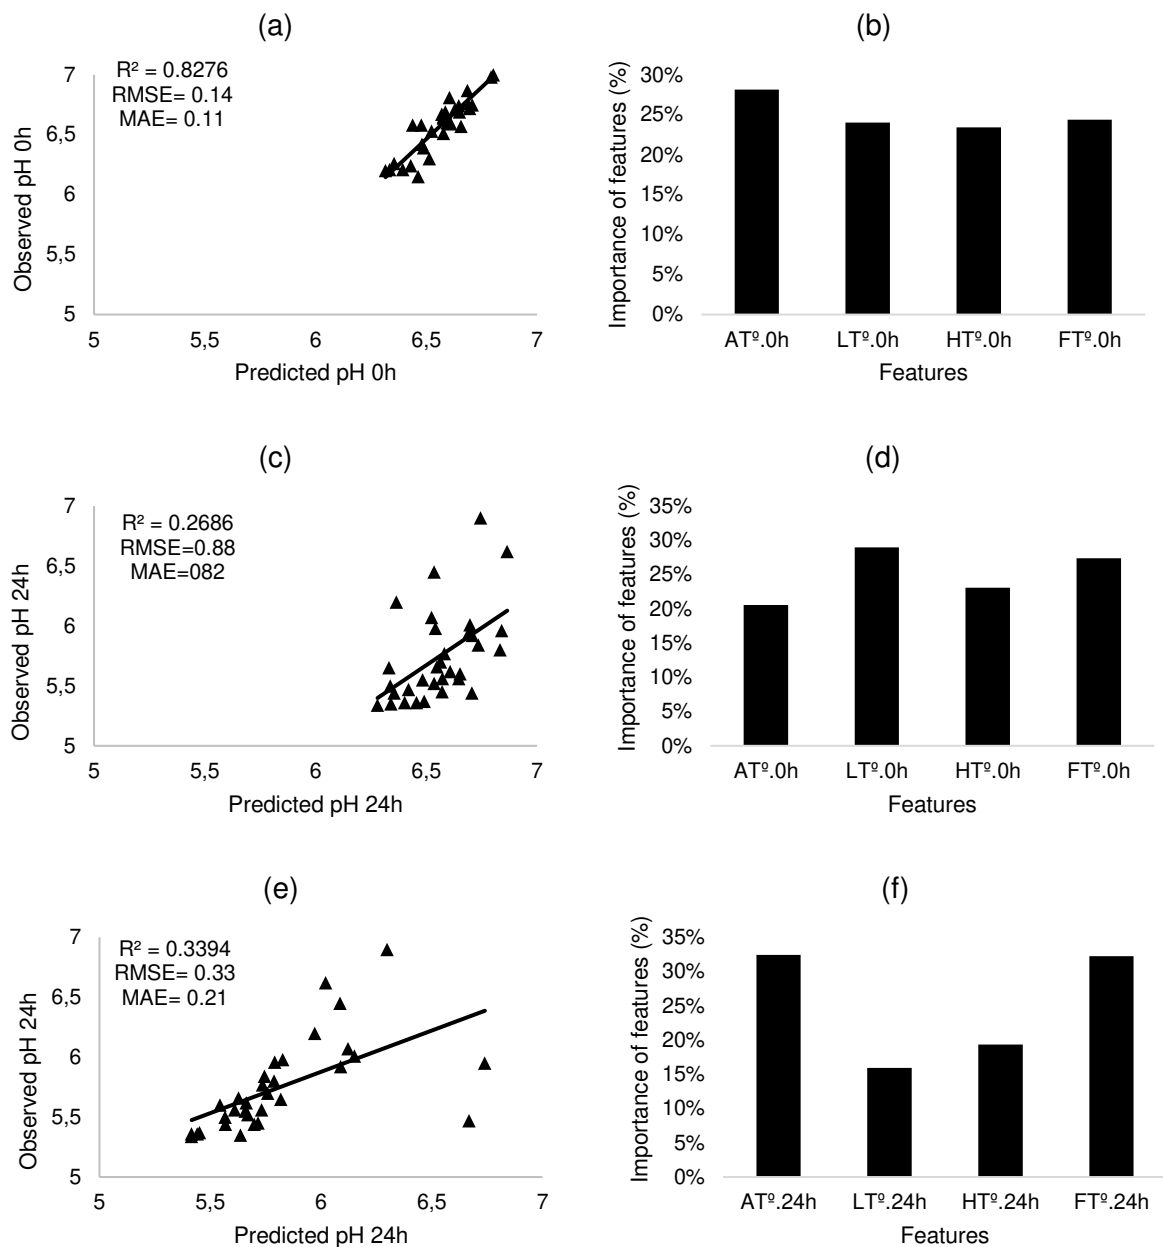


**Figure 3:** Temperature prediction using features<sup>1</sup> from thermographic images and weight (kg), and the importance of the features in the corresponding models (b,d,f). a: temperature prediction at 0h using data from thermographic images at 0h and weight. c: temperature prediction at 24h using data from thermographic images at 24h and weight. e: temperature prediction at 24h using data from thermographic images at 0h and weight.

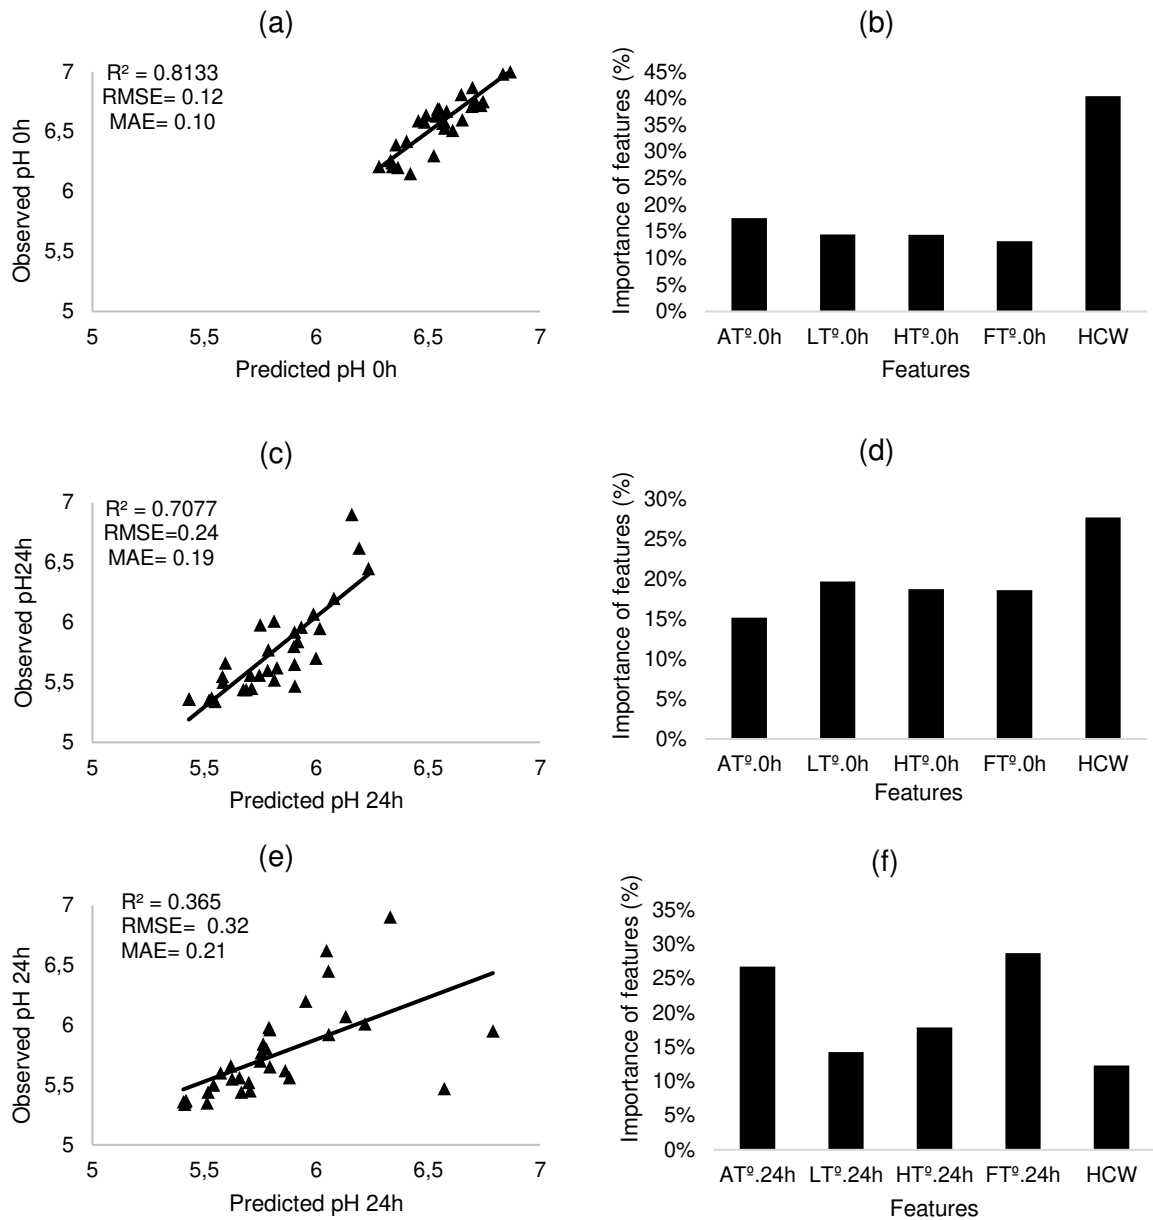
<sup>1</sup>AT<sup>0h</sup>: Average thermographic temperature of the carcass at 0h (°C); LT<sup>0h</sup>: Thermographic temperature of the circle of the carcass at 0h (°C); HT<sup>0h</sup>: Thermographic temperature of the hind of the carcass at 0h (°C); FT<sup>0h</sup>: Thermographic temperature of the front of the carcass at 0h (°C); AT<sup>24h</sup>: Average thermographic temperature of the carcass at 24h (°C); LT<sup>24h</sup>: Thermographic temperature of the circle of the carcass at 24h (°C); HT<sup>24h</sup>: Thermographic temperature of the hind of the carcass at 24h (°C); FT<sup>24h</sup>: Thermographic temperature of the front of the carcass at 24h (°C); HCW: hot carcass weight.

**Graphic 1.** Relationship between hot carcass weight HCW and ultimate temperature (T°.24h)





**Figure 4:** Prediction of pH using features<sup>1</sup> from thermographic images and the importance of the features in the corresponding models (b,d,f). a: prediction of pH at 0h using data from thermographic images at 0h. c: prediction of pH at 24h using data from thermographic images at 0h. e: prediction of pH at 24h using data from thermographic images at 24h. AT<sup>0h</sup>: Average thermographic temperature of the carcass at 0h (°C); LT<sup>0h</sup>: Thermographic temperature of the circle of the carcass at 0h (°C); HT<sup>0h</sup>: Thermographic temperature of the hind of the carcass at 0h (°C); FT<sup>0h</sup>: Thermographic temperature of the front of the carcass at 0h (°C); AT<sup>24h</sup>: Average thermographic temperature of the carcass at 24h (°C); LT<sup>24h</sup>: Thermographic temperature of the circle of the carcass at 24h (°C); HT<sup>24h</sup>: Thermographic temperature of the hind of the carcass at 24h (°C); FT<sup>24h</sup>: Thermographic temperature of the front of the carcass at 24h (°C).



**Figure 5.** Prediction of pH using features<sup>1</sup> from thermographic images and weight (kg), and the importance of the features in the corresponding models (b,d,f). a: Prediction of pH at 0h using data from thermographic images at 0h and weight. c: Prediction of pH at 24h using data from thermographic images at 0h and weight. e: Prediction of pH at 24h using data from thermographic images at 24h and weight.

<sup>1</sup> AT<sup>0h</sup>: Average thermographic temperature of the carcass at 0h (°C); LT<sup>0h</sup>: Thermographic temperature of the circle of the carcass at 0h (°C); HT<sup>0h</sup>: Thermographic temperature of the hind of the carcass at 0h (°C); FT<sup>0h</sup>: Thermographic temperature of the front of the carcass at 0h (°C); AT<sup>24h</sup>: Average thermographic temperature of the carcass at 24h (°C); LT<sup>24h</sup>: Thermographic temperature of the circle of the carcass at 24h (°C); HT<sup>24h</sup>: Thermographic temperature of the hind of the carcass at 24h (°C); FT<sup>24h</sup>: Thermographic temperature of the front of the carcass at 24h (°C); HCW: hot carcass weight (kg).