



WSTAR

**WORKSHOP ON
STATISTICAL TOOLS AND ANALYSIS FOR
SCIENTIFIC RESEARCH**

2024



HOME EDITORA

**WSTAR - WORKSHOP ON
STATISTICAL TOOLS AND ANALYSIS
FOR SCIENTIFIC RESEARCH**

Todo o conteúdo apresentado neste livro é de responsabilidade do(s) autor(es).
Esta publicação está licenciada sob [CC BY-NC-ND 4.0](https://creativecommons.org/licenses/by-nc-nd/4.0/)

Conselho Editorial

Prof. Dr. Ednilson Sergio Ramalho de Souza - Ufopa (Editor-Chefe)
Prof^ª. Dr^a. Danjone Regina Meira - USP
Prof^ª. Ms. Roberta Seixas - Unesp
Prof. Ms. Gleydson da Paixão Tavares - UESC
Prof^ª. Dr^a. Monica Aparecida Bortolotti - Unicentro
Prof^ª. Dr^a. Isabele Barbieri dos Santos - FIOCRUZ
Prof^ª. Dr^a. Luciana Reusing - IFPR
Prof^ª. Ms. Laize Almeida de Oliveira - UNIFESSPA
Prof. Ms. John Weyne Maia Vasconcelos - UFC
Prof^ª. Dr^a. Fernanda Pinto de Aragão Quintino - SEDUC-AM
Prof^ª. Dr^a. Leticia Nardoni Marteli - IFRN
Prof. Ms. Flávio Roberto Chaddad - SEESP
Prof. Ms. Fábio Nascimento da Silva - SEE/AC
Prof^ª. Ms. Sandolene do Socorro Ramos Pinto - UFPA
Prof^ª. Dr^a. Klenicy Kazumy de Lima Yamaguchi - UFAM
Prof. Dr. Jose Carlos Guimaraes Junior - Governo do Distrito Federal
Prof. Ms. Marcio Silveira Nascimento - UFRR
Prof. Ms. João Filipe Simão Kembo - Escola Superior Pedagógica do Bengo - Angola
Prof. Ms. Divo Augusto Pereira Alexandre Cavadas - FADISP
Prof^ª. Ms. Roberta de Souza Gomes - NESPEFE - UFRJ
Prof. Ms. Valdimiro da Rocha Neto - UNIFESSPA
Prof. Dr. Jeferson Stiver Oliveira de Castro - IFPA
Prof. Ms. Artur Pires de Camargos Júnior - UNIVÁS
Prof. Ms. Edson Vieira da Silva de Camargos - Universidad de la Empresa (UDE) - Uruguai
Prof. Ms. Jacson Baldoino Silva - UEFS
Prof. Ms. Paulo Osni Silvério - UFSCar
Prof^ª. Ms. Cecília Souza de Jesus - Instituto Federal de São Paulo

“Acreditamos que um mundo melhor se faz com a difusão do conhecimento científico”.

Equipe Home Editora

Renius Mello
Paulo Santana Pacheco
José Dilson Francisco da Silva
Fernanda Cristina Breda

WSTAR - WORKSHOP ON STATISTICAL TOOLS AND ANALYSIS FOR SCIENTIFIC RESEARCH

1ª Edição

Belém-PA
Home Editora
2024

© 2024 Edição brasileira
by Home Editora

© 2024 Texto
by Autor

Todos os direitos reservados

Home Editora

CNPJ: 39.242.488/0002-80

www.homeeditora.com

contato@homeeditora.com

91988165332

Tv. Quintino Bocaiúva, 23011 - Batista Campos, Belém - PA, 66045-315

Editor-Chefe

Prof. Dr. Ednilson Ramalho

Projeto gráfico

homeeditora.com

Revisão

Autores

Bibliotecária

Janaina Karina Alves Trigo Ramos

CRB-8/009166

Produtor editorial

Laiane Borges

Dados Internacionais de Catalogação na Publicação (CIP)

M531

WSTAR - Workshop on Statistical Tools and Analysis for Scientific Research / Renius Mello, Paulo Santana Pacheco, José Dilson Francisco da Silva, Fernanda Cristina Breda. – Belém: Home, 2024.

Livro digital
104p.

ISBN 978-65-6089-191-3

DOI 10.46898/home.68602589-be76-4586-a350-cb5af4cdf724

1. Estatística. 2. Internet das Coisas. 3. Inteligência Artificial. 4. Ciência da carne. 5. Visualização de dados. I. Mello, Renius. II. Pacheco, Paulo Santana. III. Silva, José Dilson Francisco da. IV. Breda, Fernanda Cristina. V. Título.

CDD 519.5

CDU 519.2

Índice para catálogo sistemático:

I. Estatística aplicada : Visualização de dados : Internet das Coisas e Inteligência Artificial



<https://www.ufsm.br/eventos/wstar2024>

Comissão organizadora:

Renius Mello

Paulo Santana Pacheco

Jeriel Dias

Bibiana Cristina Butzke

Alice Veleda Wendt

José Dilson Francisco da Silva

Suslin Raatz Thiel

Diúlia Zolin Galvani

Hugo José de Araújo Correia

Marcelle de Oliveira Benites

André Fogaça Nigeliskii

Capa: Jeriel Dias

Diagramação: Renius Mello

Realização:



Apoio:



SUMÁRIO

CAPÍTULO I: Descobrimo o mundo de IoT – internet das coisas	7
CAPÍTULO II: Aplicação da Inteligência Artificial (AI) na indústria da ciência da carne	26
CAPÍTULO III: Tamanho amostral em experimentação zootécnica	61
CAPÍTULO IV: SAS® Viya™: Descubra insights com SAS® Visual Analytics	79

APRESENTAÇÃO

A análise estatística desempenha um papel fundamental na tomada de decisões informadas e baseadas em dados nas diversas áreas, desde a pesquisa científica até o mundo dos negócios. Todavia, muitos acadêmicos e ainda enfrentam lacunas na formação em estatística, podendo limitar seu potencial de crescimento profissional e sua capacidade em contribuir de forma significativa para a sociedade.

Diante disso, foi idealizado o ***Workshop on Statistical Tools and Analysis for Scientific Research (WSTAR)***, com o propósito de oferecer capacitação em análise estatística para acadêmicos e pesquisadores nas diferentes áreas do conhecimento. Este livro visa fornecer habilidades essenciais para a análise de dados e a utilização de ferramentas estatísticas na solução de problemas práticos e complexos, conectando teoria e prática.

Com essa iniciativa, esperamos contribuir para a formação de profissionais mais qualificados, preparados para enfrentar os desafios em suas carreiras, além de fomentar uma participação ativa na sociedade, embasada em decisões analíticas e fundamentadas em dados.

CAPÍTULO I

DESCOBRINDO O MUNDO DE IoT – INTERNET DAS COISAS

Diego Serodio Costa¹

¹ SAS Software, Brasil. E-mail: diego.costa@sas.com

Resumo: Este capítulo apresenta uma visão abrangente sobre a Internet das Coisas (IoT), explorando sua história, aplicações e tecnologias fundamentais. Abordamos como dispositivos conectados interagem e trocam dados automaticamente, revolucionando setores como casas inteligentes, cidades, indústrias e saúde. Discutimos também as camadas que compõem um projeto de IoT, desde os sensores até a integração com processos empresariais, além das tecnologias de suporte, como computação em nuvem e aprendizado de máquina. Por fim, olhamos para o futuro da IoT, com destaque para tendências emergentes como AIoT e Digital Twins, e analisamos o panorama da IoT no Brasil, suas oportunidades e desafios.

Abstract: This chapter provides a comprehensive overview of the Internet of Things (IoT), exploring its history, applications, and key technologies. We cover how connected devices interact and exchange data automatically, transforming sectors such as smart homes, cities, industries, and healthcare. We also discuss the layers that make up an IoT project, from sensors to the integration with business processes, as well as supporting technologies like cloud computing and machine learning. Finally, we look to the future of IoT, highlighting emerging trends such as AIoT and Digital Twins, and analyze the IoT landscape in Brazil, its opportunities, and challenges.

1 INTRODUÇÃO

Vivemos em uma era de inovações tecnológicas, onde a conexão entre objetos físicos e o mundo digital transforma a maneira como interagimos com o ambiente ao nosso redor. E um dos conceitos mais poderosos dessa revolução é a Internet das Coisas (IoT). Esse campo da tecnologia permite que dispositivos conectados troquem dados e realizem tarefas automaticamente, sem a necessidade de intervenção humana. Seja em casas inteligentes, cidades conectadas ou na automação de fábricas, IoT está se tornando cada vez mais parte de nossas vidas. Neste capítulo, vamos explorar o que é Internet das Coisas, como funciona, quais suas principais aplicações, tecnologias possibilitadoras e incentivos para sua aplicação no Brasil.

De acordo com estudos recentes, o número de dispositivos conectados à internet já supera a população mundial. Estimativas indicam que até 2022, mais de 26 bilhões de dispositivos estarão conectados globalmente, alimentando uma rede de interações que transforma não apenas nossas casas e cidades, mas também setores como a saúde, o transporte e a indústria.

A Internet das Coisas não se refere apenas à conexão entre computadores e smartphones, mas a uma gama de dispositivos que, por meio de sensores, redes e processamento de dados, são capazes de "conversar" uns com os outros. Isso significa que eletrodomésticos, veículos, sensores industriais e até mesmo dispositivos médicos podem se conectar, fornecendo informações importantes e otimizando processos cruciais para diversas indústrias.

2 A HISTÓRIA DA INTERNET DAS COISAS

A Internet das Coisas, ou IoT, tem raízes que remontam ao início da evolução da internet e das tecnologias de comunicação. Embora o conceito de conectar dispositivos não seja exatamente novo, o termo "Internet das Coisas" foi cunhado em 1999 por Kevin Ashton, um pesquisador do MIT, durante seu trabalho com tecnologia RFID (Identificação por Radiofrequência) para rastreamento de produtos em cadeias de suprimentos. Ashton visualizou um futuro em que objetos físicos pudessem ser conectados à internet para coletar e compartilhar dados sem intervenção humana (Ashton, 2009).

No entanto, os primeiros avanços em IoT só começaram a se concretizar em meados dos anos 2000, à medida que a miniaturização de sensores e o aumento da capacidade de processamento tornaram possível conectar dispositivos de forma mais eficiente. O crescimento das conexões sem fio e o surgimento de tecnologias como o Wi-Fi, Bluetooth e redes móveis de alta velocidade (3G, 4G e, mais recentemente, 5G) foram catalisadores essenciais para a expansão do IoT em escala global.

A partir de 2005, o foco em tecnologias relacionadas à IoT começou a ganhar força, especialmente com o desenvolvimento das Redes de Sensores Sem Fio (RSSF), que contribuíram para avanços significativos na automação residencial e

industrial. As RSSFs ajudaram a superar desafios como limitações de memória e energia, bem como a melhorar a escalabilidade e robustez das redes. Entre 2008 e 2010, o termo IoT começou a se popularizar rapidamente, devido ao amadurecimento dessas redes e ao crescimento das expectativas em torno das potenciais aplicações (Kelly et al. 2013, Da Xu et al. 2014).

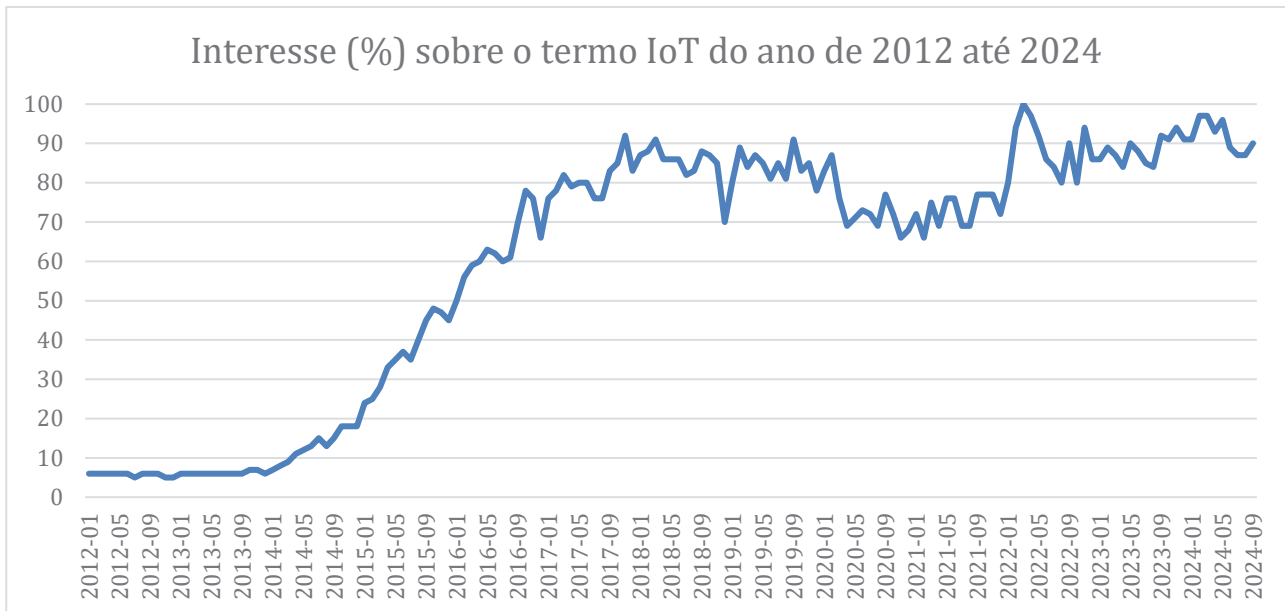


Figura 1: Percentual de interesse pelo termo “IoT” em buscas do Google de 2012 a 2024 (Fonte: Autor, Google Trends)

Um marco importante foi o lançamento do conceito de "casa inteligente" no início dos anos 2010, quando dispositivos como termostatos, lâmpadas e fechaduras começaram a ser controlados remotamente por smartphones. A partir daí, outras áreas começaram a adoção de conectividade e trabalhar em novos casos de uso, como a indústria (com a Indústria 4.0), a saúde, e até mesmo as cidades inteligentes.

Ao conectar objetos com diferentes capacidades a uma rede, abre-se espaço para o surgimento de novas aplicações. No contexto da Internet das Coisas, esses objetos são integrados à Internet, permitindo a comunicação não apenas entre dispositivos, mas também entre usuários e sistemas, o que viabiliza um leque de novas aplicações.

Entretanto, essa expansão traz novos desafios. Conectar objetos com limitações de processamento, memória, comunicação e energia exige adaptações

tecnológicas. Esses dispositivos, sendo dos mais diversos, variam em termos de recursos e qualidade, o que gera a necessidade de novas abordagens para endereçamento, roteamento e economia de recursos. Além disso, os protocolos de comunicação e roteamento nas redes de IoT podem ser diferentes dos padrões tradicionais da Internet, o que demanda a adaptação de protocolos existentes. Os dados coletados por esses dispositivos também podem apresentar ruídos ou inconsistências, exigindo que as aplicações e algoritmos sejam capazes de lidar com esses casos (Chaouchi, 2013).

Hoje, a IoT é considerada uma das principais forças motrizes da Quarta Revolução Industrial, conectando bilhões de dispositivos em todo o mundo e transformando a maneira como vivemos e interagimos com nosso ambiente.

3 EXEMPLOS DE APLICAÇÕES DA IoT

A Internet das Coisas (IoT) já está presente em diversas áreas do nosso cotidiano, revolucionando desde as atividades mais simples até grandes operações industriais e urbanas. Isso se dá, devido a adaptabilidade de se aplicar a praticamente qualquer tecnologia que forneça informações relevantes sobre seu funcionamento, a execução de uma atividade ou as condições ambientais que precisam ser monitoradas e controladas à distância. Atualmente, muitas indústrias estão adotando tecnologias de IoT para simplificar, melhorar, automatizar e controlar diferentes processos de maneira mais eficiente.

Abaixo, exploramos algumas das principais aplicações da IoT que já estão impactando a sociedade:

3.1 Casas Inteligentes

Uma das aplicações mais populares da IoT está nas casas inteligentes. Dispositivos como assistentes virtuais (Alexa, Google Home, ...), lâmpadas, termostatos, câmeras de segurança e eletrodomésticos conectados oferecem automação e controle a distância, tornando os ambientes mais eficientes e confortáveis. Com um smartphone ou tablet, é possível controlar estes dispositivos, monitorar o consumo de energia e melhorar a segurança da residência (Santos et al, 2016).

3.2 Smart Cities (Cidades Inteligentes)

Tecnologias de IoT tem transformado a estrutura tradicional das cidades, criando um cenário altamente tecnológico que envolve o conceito de cidades inteligentes. Esses avanços são possibilitados por tecnologias como redes de sensores sem fio, servidores e , Machine Learning que trabalham em conjunto para criar uma cidades inteligentes eficiente. No entanto, é essencial considerar o impacto ambiental durante o desenvolvimento dessas aplicações, adotando tecnologias energeticamente eficientes e sustentáveis para a construção da infraestrutura (Kramp, 2013).

Além disso, os veículos modernos estão cada vez mais integrados a dispositivos inteligentes que podem detectar congestionamentos de tráfego e fornecer rotas alternativas, ajudando a minimizar o trânsito nas cidades. IoT também contribui para a manutenção e monitoramento de veículos, com sensores inteligentes que permitem a troca de informações entre veículos autônomos, promovendo um fluxo de tráfego mais eficiente em comparação aos veículos dirigidos por humanos. Embora essa tecnologia ainda precise de tempo para se disseminar globalmente, os dispositivos de IoT continuarão a desempenhar um papel essencial no monitoramento e controle do tráfego e no gerenciamento de frotas.

3.3 Industrial IoT (IIoT)

No setor industrial, IoT se constitui como uma peça-chave para a Indústria 4.0. Sensores e dispositivos conectados monitoram máquinas, processos e condições ambientais, permitindo manutenção preditiva e melhor gerenciamento da produção. Isso aumenta a eficiência, reduz paradas inesperadas e melhora a qualidade dos produtos. Além disso, a integração entre sistemas de diferentes fábricas em uma cadeia de produção global é facilitada pela IoT, aumentando a colaboração e a inovação no setor (Tomáz, 2020).

A Internet das Coisas Industrial (IIoT) traz benefícios específicos que vão além dos dados tradicionalmente coletados nas fábricas, ampliando as possibilidades de otimização nas operações industriais. Um dos principais benefícios está na coleta de dados não relacionados diretamente à produção, como os dados de manutenção, controle de qualidade e fornecimento de matérias-primas. Esses dados, que muitas

vezes são difíceis de integrar aos sistemas de informação e controle de fábricas, podem ser acessados e utilizados facilmente, facilitando a otimização do planejamento e da programação de operação de uma fábrica. Além disso, o uso de dados de produção para outras finalidades, como manutenção e controle de qualidade, também pode ser melhorado pelas soluções oferecidas pelo IIoT, criando uma interconexão mais robusta entre diferentes camadas de dados dentro da fábrica e da cadeia de suprimentos (McFarlane, 2017).

Outro benefício significativo da IIoT está relacionado à coleta de dados de produtos ao longo de seu ciclo de vida. Atualmente, as informações sobre os produtos estão fragmentadas em diferentes bancos de dados de fornecedores, fabricantes, distribuidores, varejistas e prestadores de serviços, dificultando a gestão eficiente de seus ciclos de vida. Tecnologias de IoT podem ajudar a resolver esse problema ao permitir que os dados sejam coletados e conectados de forma contínua a um produto físico, desde sua fabricação até seu descarte, o que melhora o desempenho do ciclo de vida dos produtos.

3.4 Saúde

A aplicação de IoT na área da saúde é um campo extremamente promissor. Por meio desta tecnologia, médicos podem monitorar e auxiliar pacientes à distância, o que elimina vários obstáculos e abre possibilidades em comparação com a medicina tradicional. Dispositivos portáteis baseados permitem que os médicos acompanhem o estado de saúde de seus pacientes em tempo real e respondam de maneira rápida e personalizada. Esses sensores portáteis possibilitam uma abordagem individualizada para cada paciente, permitindo a análise contínua de seu estado de saúde e o cálculo de tratamentos específicos. No entanto, para que os dados em tempo real sejam transmitidos corretamente, é essencial uma conexão de Internet estável. Embora IoT na saúde esteja em rápido desenvolvimento, sua aplicação ainda não está amplamente difundida em todos os setores da medicina tradicional (Rayan, 2021).

Com o crescimento contínuo de pesquisas médicas, espera-se que a IoT atraia cada vez mais atenção nos próximos anos. Os profissionais de saúde enfrentam o desafio de lidar com grandes volumes de dados e sua interpretação para tomar decisões precisas. Novas tecnologias baseadas em IoT têm o potencial

de acelerar e facilitar esse processo. Com o aumento da digitalização dos registros médicos, há uma quantidade crescente de dados a serem analisados, o que demanda tempo e esforço. Além disso, é necessário treinar a equipe médica no uso de tecnologias baseadas em inteligência artificial (IA), que estão fortemente ligadas à IoT.

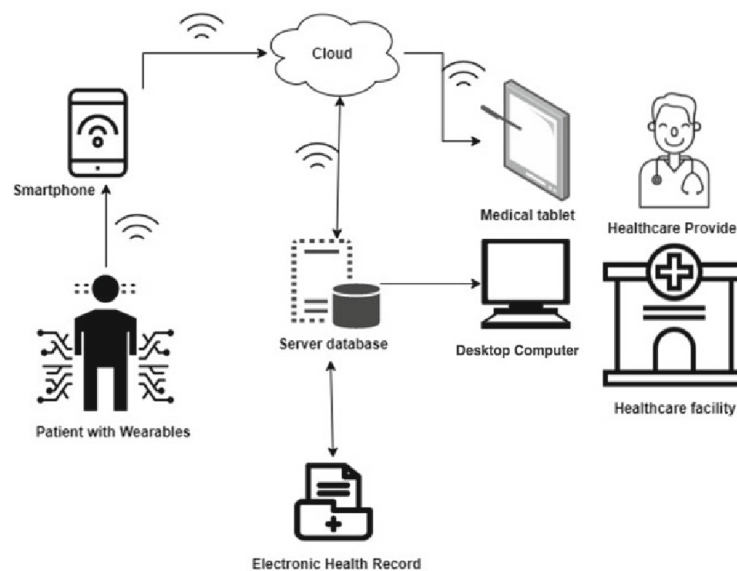


Figura 2: Conceito de IoT para a saúde (Rayan, 2021)

Com a integração entre IoT e IA, os médicos podem personalizar ainda mais os tratamentos de acordo com as necessidades apresentadas por cada paciente. Essas tecnologias permitem lidar com um volume maior de informações, armazenando e analisando dados de maneira eficiente para acompanhar o progresso de uma doença ou condição. Ao combinar a experiência prática com os novos métodos de diagnóstico e análise de dados, pode-se aumentar a precisão e velocidade com que diagnósticos são realizados (Silva, J. R., 2020).

IoT para a área de saúde está introduzindo tecnologias conectadas à rede, incluindo dispositivos vestíveis (*wearables*) que detectam, conectam e interagem com outros dispositivos similares por meio da Internet. Essa interoperabilidade está revolucionando a produção, uso e distribuição de dados na área da saúde. Cada vez mais, pessoas utilizam esses sistemas para monitorar aspectos de suas vidas como dieta, sono, sinais vitais e atividades físicas, enquanto tecnologias IoT coletam e analisam dados ambientais que influenciam a saúde individual. Esse avanço está abrindo caminho para novas alternativas e soluções médicas.

3.5 IoT no Cotidiano

Além de aplicações específicas em áreas como casas e indústrias apresentadas acima, a Internet das Coisas já faz parte do nosso dia a dia de maneiras mais sutis. Dispositivos conectados podem estar presentes em *wearables*, como relógios e pulseiras que monitoram atividades físicas, sistemas de pagamento por aproximação, e até em veículos, com carros conectados que fornecem dados sobre a condição do veículo e navegação.

4 PARTES FUNDAMENTAIS DE UM PROJETO DE IoT

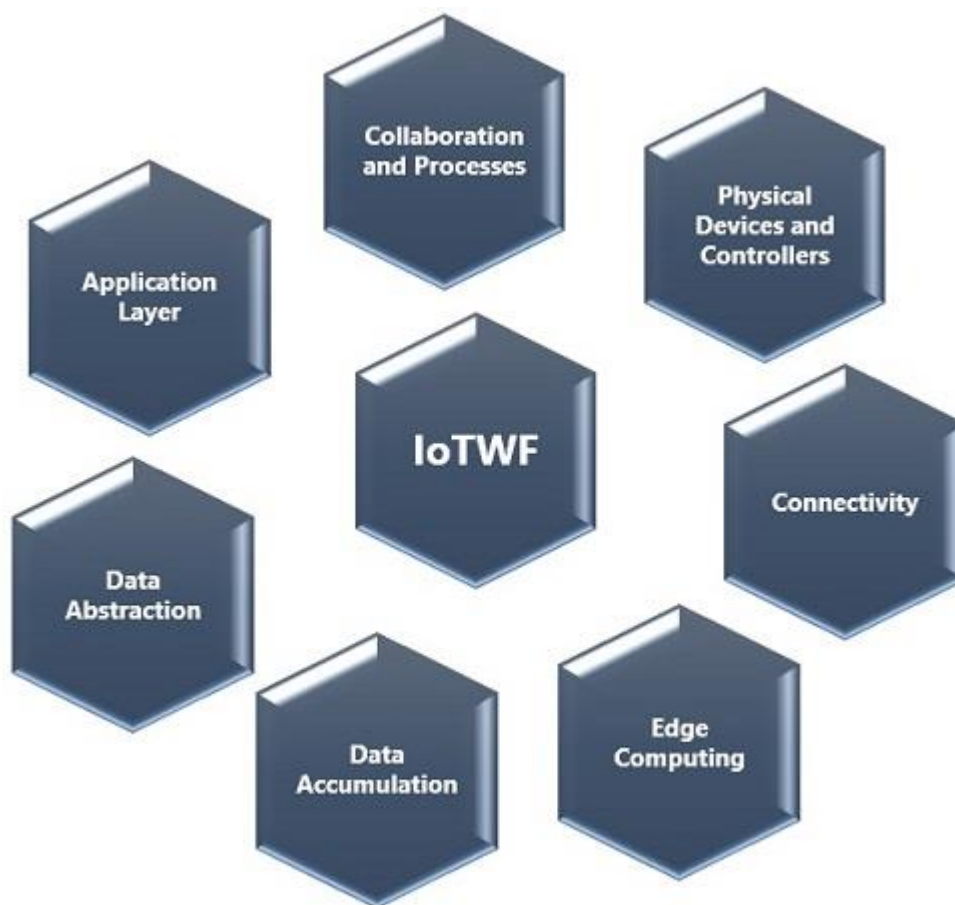


Figura 3: Arquitetura de referência pelo IoTWF

Um projeto de IoT é composto por várias camadas interconectadas, que vão desde os dispositivos físicos até a integração final com processos empresariais ou operacionais. O IoT World Forum (IoTWF) padronizou uma arquitetura de referência em sete camadas para organizar os componentes de uma solução de IoT.

Cada camada desempenha um papel específico no fluxo de dados e nas funcionalidades de um projeto IoT (IoTWF, 2023).

4.1 Dispositivos Físicos e Controladores (Things)

Essa primeira camada é composta pelos próprios dispositivos ou "coisas" que formam a base da Internet das Coisas. Aqui estão incluídos sensores, atuadores e equipamentos físicos, como máquinas industriais, dispositivos domésticos ou sensores ambientais. Eles são responsáveis pela captura dos dados no mundo físico, fornecendo informações como temperatura, umidade, movimento ou consumo de energia. Essa camada também inclui controladores que atuam localmente nos dispositivos para automatizar funções e controlar aspectos dos sistemas.

A arquitetura de um sensor IoT é composta por quatro elementos fundamentais: energia, sensores, processamento e comunicação. A energia é responsável por alimentar os dispositivos, e pode ser fornecida por diferentes fontes, como energia elétrica, baterias ou até mesmo fontes renováveis, como a solar. Já os sensores são os componentes que fazem a interação com o ambiente, capturando dados de variáveis físicas, como temperatura, umidade, movimento e pressão, tornando-os essenciais para monitoramento e controle em projetos de IoT (Tomáz, 2020).




Figura 4: Arquitetura de um sensor IoT (Sousa, 2018)

O processamento ocorre por meio de um microprocessador e memória embutida nos dispositivos, onde os dados coletados pelos sensores são armazenados e tratados antes de serem enviados para uma base de dados ou plataforma que irá interpretá-los de acordo com a necessidade da aplicação. Por fim, a comunicação entre os dispositivos pode ser realizada por meio de conexões com ou sem fio, frequentemente utilizando sinais de rádio frequência (RF), ou Wi-Fi/Bluetooth para transmitir e receber dados, permitindo a interação entre os dispositivos dentro da rede de um projeto.

4.2 Conectividade

A segunda camada trata da transmissão de dados entre os dispositivos e o restante do sistema IoT. Ela funciona como um sistema de transporte que garante que os dados cheguem com eficiência e segurança ao destino, seja em um servidor na nuvem ou em um data center local. As tecnologias utilizadas aqui podem incluir redes móveis (3G/4G/5G), Wi-Fi, LoRaWAN, Bluetooth, entre outras. A camada de conectividade é crucial, pois garante que os dados sejam transmitidos em tempo real ou quase real, dependendo das necessidades da aplicação.

4.3 Edge Computing

Nessa camada, também conhecida como "computação na borda", ocorre o processamento inicial dos dados mais próximo dos dispositivos físicos. A computação de borda reduz a latência ao permitir que decisões rápidas sejam tomadas localmente, onde o dado é gerado, antes de enviá-lo para a nuvem. Isso é particularmente útil em aplicações onde o tempo de resposta é crítico, como em veículos autônomos ou monitoramento de saúde em tempo real. Funções como conversão de protocolos, roteamento de dados e tomadas de decisão imediatas ocorrem nesta camada.

4.4 Acúmulo de Dados

Os dados gerados pelos dispositivos e processados na borda precisam ser armazenados para análise posterior. Essa camada atua como um depósito de dados temporário ou permanente, acumulando grandes volumes de informações em um *lake* para serem processados em seguida. O armazenamento de dados é essencial para garantir que todos os dados coletados estejam prontos para serem analisados e possam ser acessados conforme necessário.

4.5 Abstração de Dados

Aqui, os dados armazenados são preparados para análise, sendo agrupados, priorizados e filtrados. O objetivo dessa camada é abstrair dados irrelevantes e organizar as informações mais importantes para que possam ser utilizadas de maneira eficiente pelas aplicações que virão a seguir. A abstração de dados facilita a agregação de diferentes fontes de dados e transforma informações brutas em dados utilizáveis.

4.6 Camada de Aplicação

A camada de aplicação é o centro de controle do sistema IoT, onde o valor real dos dados é gerado. Nessa camada, as informações coletadas e processadas nas camadas anteriores são utilizadas para tomada de decisões, otimização de processos e monitoramento. As aplicações de IoT são responsáveis por executar uma ampla gama de funções, desde o controle de dispositivos, análise de padrões até a configuração de regras de automação e alarmes.

4.7 Colaboração e Processos

Por fim, a última camada integra todo o sistema de IoT com o **mundo real**, conectando pessoas e processos às tecnologias e dados gerados. Nesta camada, as organizações podem tomar decisões baseadas nos dados coletados, otimizar operações e gerar valor. É aqui que a tecnologia IoT tem um impacto direto nos negócios ou na vida cotidiana, ajudando a melhorar processos, reduzir custos, gerar novos modelos de negócios e melhorar a qualidade de vida.

5 TECNOLOGIAS ENVOLVIDAS EM UM PROJETO DE IoT

A implementação de um projeto de IoT depende de várias tecnologias que possibilitam o processamento e a análise dos dados coletados pelos dispositivos. Duas das tecnologias mais relevantes para a aplicação de um projeto de IoT são a Computação em Nuvem (*Cloud Computing*) e o Aprendizado de Máquina (*Machine Learning*). A combinação dessas tecnologias é o que permite que os dispositivos conectados tomem decisões inteligentes e otimizem processos de forma automatizada.

5.1 Nuvem (*Cloud Computing*)

A computação em nuvem refere-se à disponibilização em massa de recursos computacionais sob demanda por meio da internet, com um modelo de pagamento conforme o uso. Em vez de adquirir e manter datacenters e servidores físicos, é possível acessar serviços, como processamento, armazenamento e bancos de dados, de acordo com a necessidade do projeto, utilizando um provedor de nuvem público ou privado.

O conceito de computação em nuvem tem chamado a atenção tanto da indústria quanto do meio acadêmico por seu potencial de transformação dos serviços tecnológicos. Através da nuvem, é possível obter o desempenho desejado, com alta disponibilidade, escalabilidade praticamente infinita, tolerância a falhas e diversas outras funcionalidades (Ashraf et. Al, 2013).




Figura 5: Provedor público de serviços de nuvem (Ahmad, 2017)

Uma das principais vantagens que atrai as empresas para essa tecnologia é a redução de custos. Não há necessidade de investir em equipamentos ou na manutenção de infraestrutura física, já que o provedor de nuvem se encarrega desses recursos, garantindo a manutenção e a disponibilidade dos serviços.

A nuvem é composta por uma combinação de recursos computacionais, desde processadores, memórias e discos rígidos, até serviços avançados de escalabilidade e gestão de riscos. Ela oferece diferentes modelos de serviço para atender diversas necessidades, como o PaaS (Plataforma como Serviço), que facilita a criação de ambientes para desenvolvimento de sistemas ou serviços específicos, conforme as demandas dos usuários (Ahmad, 2017).

Outro modelo importante é o IaaS (Infraestrutura como Serviço), que disponibiliza toda a infraestrutura necessária para que uma empresa opere em

nuvem, reduzindo a dependência de espaços físicos para datacenters, sem comprometer o desempenho. O IaaS permite que os usuários tenham acesso a recursos de hardware de maneira ágil, com rápida instalação e menor necessidade de manutenção.

Além disso, o SaaS (Software como Serviço) possibilita a criação e utilização de ferramentas de software diretamente na nuvem, oferecendo rápida resposta e fácil implementação, de acordo com as necessidades específicas dos usuários.

5.2 Machine Learning (Aprendizado de Máquina)

Machine Learning (ML) é um ramo da inteligência artificial que permite que sistemas aprendam com dados e melhorem seu desempenho ao longo do tempo, sem a necessidade de serem explicitamente programados para cada tarefa. Através de algoritmos e modelos estatísticos, um modelo de ML analisa grandes volumes de dados, identifica padrões e faz previsões, permitindo a automação de decisões que anteriormente dependiam da intervenção humana.

Em projetos de Internet das Coisas (IoT), o aprendizado de máquina se torna essencial devido à enorme quantidade de dados gerados por dispositivos conectados. Esses dispositivos estão constantemente capturando informações, como temperatura, pressão, movimento, consumo de energia, entre outros. O papel do ML é processar esses dados, extrair insights e automatizar a resposta aos eventos em tempo real.

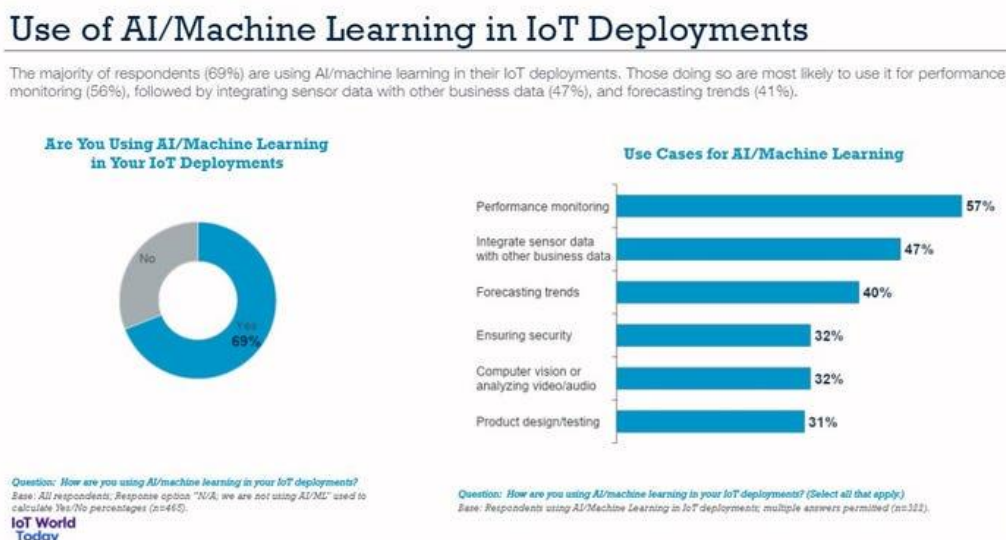


Figura 6: Uso de IA e ML em sistemas de IoT (IoT World Today, 2020)

Há diversos tipos de métodos de Machine Learning, diferenciando-se pela aplicação de diferentes algoritmos e técnicas (Patel, 2023):

Aprendizado supervisionado: O modelo é treinado com um conjunto de dados previamente rotulados, onde o resultado esperado já é conhecido. Após o treinamento, o algoritmo pode fazer previsões com base em novos dados.

Aprendizado não-supervisionado: O algoritmo trabalha com dados sem rótulos, ou seja, ele precisa identificar padrões e estruturas por conta própria. Esse tipo de aprendizado é frequentemente usado para agrupamento e redução de dimensionalidade.

Aprendizado por reforço: No aprendizado por reforço, o algoritmo aprende com base em um sistema de recompensas e penalidades. Ele toma decisões, observa o resultado e ajusta suas ações para maximizar a recompensa a longo prazo.

Estes tipos de técnicas e algoritmos são essenciais para projetos de IoT pois permitem que os sistemas tomem decisões inteligentes de maneira autônoma e em tempo real. Sem o ML, é ineficiente e inviável a análise rápida de grandes quantidades de dados, como os que são gerados a partir de sensores.

6 O FUTURO DA IoT: AIoT E DIGITAL TWINS

À medida que a Internet das Coisas continua a evoluir, novas tecnologias emergem, ampliando as possibilidades e o impacto que a IoT pode ter em diversos setores. Duas dessas tendências que estão moldando o futuro da IoT são o AIoT (Artificial Intelligence of Things) e os Digital Twins. Ambas prometem levar a IoT a novos patamares de inteligência, automação e capacidade de simulação.

6.1 AIoT (Artificial Intelligence of Things)

O AIoT é a convergência da Inteligência Artificial (IA) com a IoT, onde dispositivos conectados não apenas coletam e compartilham dados, mas também aprendem e tomam decisões de forma autônoma. Com o AIoT, os sistemas IoT se tornam mais inteligentes, usando algoritmos de machine learning e deep learning para interpretar os dados em tempo real, identificar padrões e realizar ações sem a necessidade de intervenção humana. Essa combinação potencializa os benefícios

da IoT em diversos campos, como cidades inteligentes, fábricas automatizadas e veículos autônomos.

Um exemplo prático do AIoT é a manutenção preditiva em ambientes industriais. Sensores IoT monitoram equipamentos em tempo real, enquanto algoritmos de IA analisam os dados coletados e prevêm falhas antes que elas ocorram. Isso não apenas reduz os custos de manutenção, mas também aumenta a eficiência e a segurança.

6.2 Digital Twins

Os Digital Twins são representações virtuais de objetos ou sistemas físicos, que espelham seus estados e comportamentos em tempo real. No contexto de IoT, os gêmeos digitais são criados a partir dos dados coletados por sensores e dispositivos IoT, permitindo que empresas e engenheiros simulem, monitorem e controlem ativos físicos de maneira precisa.

Essas representações digitais são especialmente úteis em indústrias como a manufatura, onde os gêmeos digitais podem ser usados para testar alterações em uma linha de produção sem impactar a operação física. Na construção civil, eles são aplicados para modelar edifícios e prever o impacto de mudanças estruturais antes mesmo da construção. Além disso, em cidades inteligentes, gêmeos digitais de infraestruturas de redes de energia e sistemas de transporte podem otimizar operações, garantindo uma melhor gestão dos recursos e resposta a emergências.

O futuro de IoT com AIoT e Digital Twins promete não apenas maior automação e eficiência, mas também a capacidade de criar sistemas que se adaptam e respondem rapidamente a novas demandas, proporcionando uma interação cada vez mais fluida entre o mundo físico e digital.

7 A REALIDADE DO IoT NO BRASIL

No Brasil, o desenvolvimento e a adoção da Internet das Coisas (IoT) têm mostrado avanços consideráveis nos últimos anos, impulsionados pelo crescimento das tecnologias digitais e pela necessidade de inovação em diversos setores. No entanto, o país ainda enfrenta desafios estruturais que limitam a expansão plena do IoT em comparação com outras regiões mais desenvolvidas. Em 2019, o governo brasileiro implementou o Plano Nacional de Internet das Coisas com o objetivo de fomentar o desenvolvimento da IoT em quatro áreas prioritárias: agronegócio,

saúde, cidades inteligentes e indústria. Cada uma dessas áreas foi selecionada com base no potencial de inovação e na demanda nacional por soluções tecnológicas.

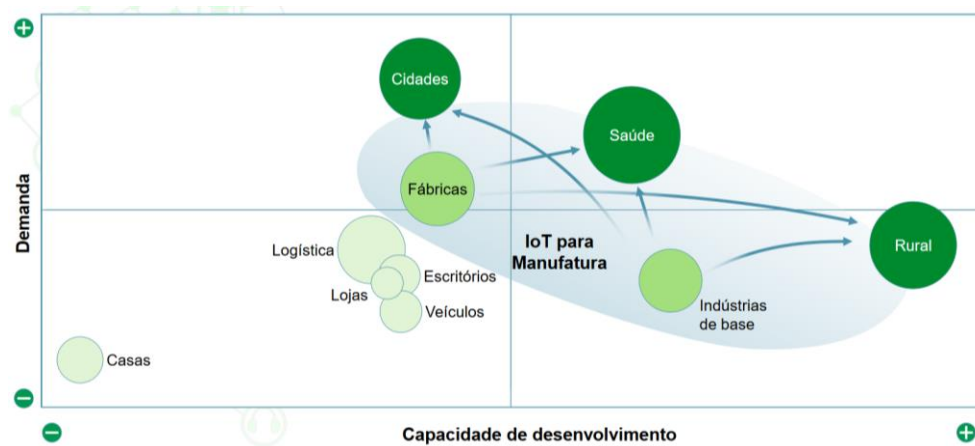


Figura 7: Demanda x Capacidade de Desenvolvimento x Oferta (MCTIC, 2019)

No agronegócio, por exemplo, o Brasil tem grande oportunidade de liderar globalmente com tecnologias de IoT voltadas para o aumento da produtividade agrícola e a sustentabilidade. Na saúde, a IoT está sendo utilizada para melhorar o acesso a cuidados médicos, com a descentralização do monitoramento de pacientes e o uso de dispositivos inteligentes para coleta de dados de saúde em tempo real. Nas cidades inteligentes, as soluções IoT estão transformando a mobilidade urbana, a segurança pública e a gestão eficiente de recursos. Já na indústria, a IoT é vista como uma maneira de aumentar a produtividade, impulsionar novos modelos de negócios e promover a cooperação entre cadeias produtivas.

Entretanto, um dos maiores desafios para a expansão da IoT no Brasil é a regulação e a segurança dos dados. A Lei Geral de Proteção de Dados (LGPD), aprovada em 2018, trouxe um importante marco regulatório para garantir a privacidade dos dados coletados por dispositivos IoT. Ao mesmo tempo, a Agência Nacional de Telecomunicações (Anatel) tem trabalhado para flexibilizar as barreiras regulatórias, facilitando a adoção em larga escala de aplicações IoT no país (Zuffo, 2019).

Esses esforços, juntamente com o apoio do governo e a colaboração entre empresas e instituições de pesquisa, mostram que o Brasil está caminhando para se tornar um importante polo de inovação em IoT, com potencial para gerar impacto socioeconômico significativo nos próximos anos.

8 CONCLUSÃO

A Internet das Coisas está transformando a maneira como nos conectamos e interagimos com o mundo ao nosso redor. Desde casas inteligentes até sistemas industriais avançados, IoT está integrando tecnologia em aspectos cotidianos, trazendo benefícios significativos como automação, eficiência e personalização. O avanço de tecnologias como Edge Computing, Computação em Nuvem e Machine Learning tem acelerado o crescimento dessa revolução digital, e o futuro da IoT aponta para inovações ainda mais revolucionárias, como o AIoT e os Digital Twins, que vão aproximar cada vez mais o mundo físico e digital.

No Brasil, a adoção do IoT tem avançado, com aplicações promissoras no agronegócio, cidades inteligentes e saúde, apesar dos desafios de infraestrutura e regulamentação. Com a implementação do 5G e o aumento dos investimentos em tecnologia, o país está em uma trajetória de expansão que promete integrar IoT em diversas esferas da sociedade.

À medida que continuamos a explorar e aplicar o potencial da IoT, é fundamental que empresas, governos e cidadãos compreendam o papel dessas tecnologias no futuro. O impacto da Internet das Coisas vai além da conveniência, criando oportunidades para inovação, melhoria da qualidade de vida e soluções sustentáveis para os desafios globais.

REFERÊNCIAS

- AHMAD, Ishrat; BAKHT, H.; MOHAN, UCloud Computing – A Comprehensive Definition. *Journal of Computing and Management Studies*, v. 1, n. 1, p. 1-20, 30 jan. 2017. Disponível em: <https://www.researchgate.net/publication/314072571>.
- Ashraf, A., et. al (2013) Introduction to Cloud Computing Technologies. In *Developing Cloud Software: Algorithms, Applications, and Tools* (pp. 1-23).
- Ashton, K. (2009). That ‘internet of things’ thing. *RFiD Journal*.
- Chaouchi, H. (2010). *The internet of things: connecting objects to the Web*. John Wiley & Sons.
- Da Xu, L., He, W., and Li, S. (2014). Internet of Things in industries: A survey. *Industrial Informatics, IEEE Transactions on*, 10(4):2233–2243.
- Kramp, T., van Kranenburg, R., & Lange, S. (2013). Introduction to the Internet of Things. In A. Bassi et al. (Eds.), *Enabling Things to Talk* (pp. 1-10). Springer. DOI: 10.1007/978-3-642-40403-0_1
- Kelly, S. D. T., Suryadevara, N. K., and Mukhopadhyay, S. C. (2013). Towards the implementation of IoT for environmental condition monitoring in homes. *Sensors Journal, IEEE*, 13(10):3846–3853.
- McFarlane, Duncan (2017). University of Cambridge Institute for Manufacturing. *Industrial Internet of Things: Unleashing the Potential of Connected Products and Services*. Acesso em: <https://www.ifm.eng.cam.ac.uk/uploads/DIAL/industrial-internet-of-things-report.pdf>
- Santos, B. P., Silva, et. al. (2016). *Internet das Coisas: da Teoria à Prática*. Universidade Federal de Minas Gerais. Disponível em: <https://homepages.dcc.ufmg.br/~mmvieira/cc/papers/internet-das-coisas.pdf>.
- Tomáz, M. R. S. Internet of Things (IoT) e as profundas modificações nos processos industriais (2020). *Revista Científica Núcleo do Conhecimento*. Disponível em: <https://www.nucleodoconhecimento.com.br/tecnologia/internet-of-things>.
- SILVA, J. R.; OLIVEIRA, M. A. (2020) A importância da Internet das Coisas na saúde. *Pesquisa em Ciência da Informação*, v. 10, n. 2, p. 45-60, 2021. DOI: 10.1590/0103-6513.2021.002.
- Rayan, R. A., Tsagkaris, C., & Iryna, R. B. (2021). *The Internet of Things for Healthcare: Applications, Selected Cases and Challenges*. In G. Marques et al. (Eds.), *IoT in Healthcare and Ambient Assisted Living* (pp. 1-13). Springer Nature Singapore Pte Ltd. https://doi.org/10.1007/978-981-15-9897-5_1

CAPÍTULO II

APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL (AI) NA INDÚSTRIA DA CIÊNCIA DA CARNE

Renius Mello², José Dilson Francisco da Silva², Fernanda Cristina Breda², Jeriel Dias², Bibiana Cristina Butzke², Suslin Raatz Thiel², Diúlia Zolin Galvani², Marcelle de Oliveira Benites², Hugo José de Araújo Correia², André Fogaça Nigeliskii²

² Universidade Federal de Santa Maria (UFSM), Santa Maria/RS, Brasil. E-mail: renius.mello@ufsm.br

Resumo: O aumento da insegurança alimentar e a crescente demanda por carne exige soluções inovadoras para garantir a produção sustentável. A inteligência artificial (AI) surge como uma ferramenta para melhorar a produção e a qualidade da carne, através de tecnologias como visão computacional e aprendizado de máquina. Essas tecnologias estão sendo aplicadas em várias etapas da cadeia de produção, desde a avaliação de carcaças até o controle de qualidade de carnes e produtos cárneos. Técnicas de análise de imagens digitais são usadas para prever a composição da carne e identificar defeitos, enquanto redes neurais são aplicadas para classificar cortes de carne com alta precisão. Embora a AI ofereça grandes oportunidades para otimizar a produção e reduzir custos, há desafios relacionados ao alto custo de implementação e complexidade das operações. Todavia, a IA pode desempenhar um importante papel na modernização da indústria de carne. Assim, nosso objetivo é inspirar e oferecer *insights* valiosos a acadêmicos, pesquisadores e profissionais da indústria, incentivando a exploração e adoção da AI na ciência da carne.

Palavras-chave: análise de imagens; aprendizado de máquina; processamento de carnes; qualidade da carne; visão computacional.

Abstract: The increase in food insecurity and the growing demand for meat require innovative solutions to ensure sustainable production. Artificial intelligence (AI) emerges as a tool to enhance meat production and quality through technologies such as computer vision and machine learning. These technologies are being applied at various stages of the production chain, from carcass evaluation to quality control of meat and meat products. Digital image analysis techniques are used to predict meat composition and identify defects, while neural networks are applied to classify meat cuts with high precision. Although AI presents great opportunities to optimize production and reduce costs, challenges remain regarding the high cost of implementation and operational complexity. Nevertheless, AI can play an important role in modernizing the meat industry. Thus, our aim is to inspire and offer valuable insights to academics, researchers, and industry professionals, encouraging the exploration and adoption of AI in meat science.

Keywords: image analysis; machine learning; meat processing; meat quality; computer vision.

1 INTRODUÇÃO

A insegurança alimentar tem aumentado globalmente desde 2019 e projeta-se que 670 milhões de pessoas (8% da população mundial) enfrentarão a fome até 2030 (FAO, IFAD, UNICEF, WFP & WHO, 2022). Em 2021, 11,7% da população mundial estava em grave situação de insegurança alimentar, apesar da Agenda 2030, implementada em 2015, e de várias iniciativas para erradicar a fome. A falta de resiliência na maioria dos sistemas alimentares e o crescimento populacional contínuo são fatores que contribuem para esse cenário de insegurança alimentar (How et al., 2020).

De acordo com o relatório *Agricultural Outlook 2023–2032* da Organização para a Cooperação e Desenvolvimento Econômico (OCDE) e da Organização para a Alimentação e Agricultura (FAO), espera-se que a demanda global por carne *per capita* aumente 2% entre o período base de 2020–2022 e 2032. Para atender esse crescimento, ainda que moderado, a oferta de carne continuará a se expandir, com produção global de carne projetada em 382 milhões de toneladas (+12%) até 2032 (OCDE/FAO, 2023).

Todavia, a indústria da carne frequentemente enfrenta desafios relacionados à falta de mão de obra qualificada e condições de trabalho muitas vezes inadequadas. Dessa forma, a transição para linhas de processamento automatizadas e inteligentes é essencial. Apesar disso, o nível de automação e a adoção de tecnologias inteligentes variam substancialmente entre os diferentes segmentos da indústria, pois cada etapa do processamento demanda soluções específicas de automação.

Assim, torna-se essencial incorporar tecnologias avançadas no ecossistema de produção de alimentos para garantir a segurança alimentar global. Nesse sentido, a Inteligência Artificial (AI – *Artificial Intelligence*) tem sido sugerida como uma ferramenta para combater a pobreza e aumentar a produção agrícola (Goralski & Tan, 2022), desempenhando um papel crucial na melhoria dos quatro pilares da

segurança alimentar: acessibilidade, estabilidade, utilização e disponibilidade (Chamara et al., 2020). A AI combina várias disciplinas científicas, incluindo lógica matemática, estatística e probabilidades, com o objetivo de replicar habilidades cognitivas humanas por meio de sistemas computacionais (Redhu et al., 2022).

A inteligência artificial já tem sido utilizada com sucesso em diversas áreas, tais como reconhecimento de texto (Mahadevkar et al., 2024), voz (You et al., 2018) e fala (Du, 2023), saúde (Bohr & Memarzadeh, 2020), agroalimentar (Kutyauripo et al., 2023), alimentos e nutrição (Miyazawa et al., 2022), autenticação de identidade (Islam et al., 2019; Loro da Silva et al., 2024) e carne cultivada (Todhunter et al., 2024).

2 INTELIGÊNCIA ARTIFICIAL

A inteligência artificial (AI) é um conceito amplo e não se restringe a uma única definição. AI envolve “*computadores que executam tarefas cognitivas geralmente atribuídas à mente humana, como aprendizado e resolução de problemas*”, conforme descrito por Baker & Smith (Zawacki-Richter et al., 2019). A AI pode ser dividida e subdividida em várias categorias (Figura 1), abrangendo diversas tecnologias, incluindo visão computacional (CVS – *Computer Vision Systems*), aprendizado de máquina (ML – *Machine Learning*), processamento de linguagem natural (NLP – *Natural Language Processing*), sistemas especialistas (ES – *Expert Systems*) e robótica.

O sistema de visão computacional (CVS – *Computer Vision System*), desenvolvido na década de 1960, é um ramo fundamental da inteligência artificial, responsável pelo estudo de como os computadores adquirem, processam, analisam e interpretam imagens digitais (DIA – *Digital Image Analysis*), vídeos (VIA – *Video Image Analysis*) e outras entradas visuais, capacitando-os a imitar a visão humana. Por meio do CVS, máquinas são treinadas para utilizar câmeras, dados e algoritmos, possibilitando que essas tarefas sejam realizadas de forma eficiente e com alta precisão. O CVS não depende de estruturas biológicas humanas, como a retina, mas se fundamenta em diversas áreas, incluindo matemática, métodos numéricos e estatística, processamento de imagens, computação gráfica, tecnologias de informação, sensores, bancos de dados, *big data*, aprendizado de

máquina e aprendizado profundo (Medathati et al., 2016). Em alguns casos, a velocidade e precisão de reconhecimento do CVS superam as capacidades humanas.

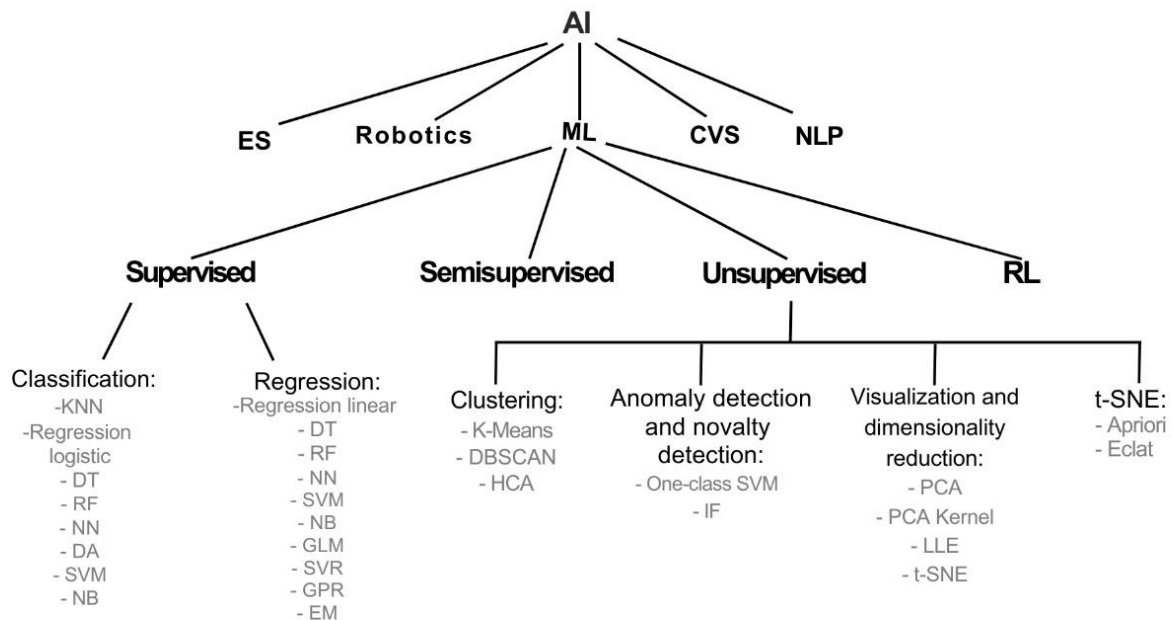


Figura 1. Classificação da inteligência artificial (adaptado de Kutyauro et al., 2023; Esmaily et al., 2024).

Abreviaturas: AI = Artificial Intelligence; ES = Expert Systems; ML = Machine Learning; CVS = Computer Vision System; NLP = Natural Language Processing; RL = Reinforcement Learning; KNN = K-Nearest Neighbor; DT = Decision Tree; RF = Random Forest; NN = Neural Network; DA = Discriminant Analysis; SVM = Support Vector Machine; NB = Naive Bayes; GLM = General Language Model; SVR = Support Vector Regression; GPR = Ground Penetrating Radar; EM = Ensemble Methods; DBSCAN = Density-Based Spatial Clustering of Applications with Noise; HCA = Hierarchical Cluster Analysis; IF = Isolation Forest; PCA = Principal Component Analysis; LLE = Locally Linear Embedding; t-SNE = t-Distributed Stochastic Neighbor Embedding

Os CVS emergem como uma alternativa promissora aos métodos convencionais de avaliação, oferecendo a vantagem de fornecer resultados objetivos de maneira rápida, não destrutiva, e sem a necessidade de reagentes químicos, tornando-a sustentável para a análise da carne. Modzelewska-Kapituła & Jun (2022) revisaram as técnicas de CVS, que incluem a análise de imagens digitais capturadas por câmeras digitais, ultrassom e tomografia computadorizada, permitindo a análise tanto de características externas (cor) quanto internas (composição química) da carne, bem como sua automação em processos industriais.

A aquisição de informações sobre a carne por meio de CVS pode ser tanto macroscópica (Balage et al., 2018) quanto microscópicas (Monteschio et al., 2019). Essas imagens podem ser capturadas por uma variedade de dispositivos, incluindo câmeras digitais convencionais ou *smartphones* (Meunier et al., 2020), além de métodos como ultrassom – US (Fiore et al., 2020), ressonância magnética nuclear – RMN (Lambe et al., 2021), tomografia computadorizada – TC (Xiberta et al., 2018), absorciometria de raios X de dupla energia - AXD (López-Campos et al., 2018), espectroscopia no infravermelho próximo e imagem hiperespectral (Balage et al., 2018; Ma & Sun, 2020).

As câmeras digitais e *scanners* são úteis para captar informações sobre as características externas das carcaças de animais. Em contrapartida, técnicas como US, RMN, TC e AXD são empregadas para adquirir dados sobre as características internas da carne, as quais não são visíveis externamente. Tais técnicas foram revisadas detalhadamente no estudo de Scholz et al. (2015). Segundo López-Campos et al. (2018), o método AXD destaca-se como o mais promissor devido à sua operação com baixos níveis de radiação em comparação com a TC, além de ser relativamente econômico, com alta velocidade de coleta de dados, confiabilidade e facilidade de uso. Embora a RMN seja um método rápido, preciso e simples, é oneroso e limitado a estimar apenas gordura e água. O US também é de alto custo e fornece informações de uma área de amostra reduzida, com resultados influenciados pela temperatura e anisotropia dos tecidos. A TC, embora precisa e capaz de visualizar gordura, carne magra e ossos, é um método de alto custo, demorado e requer experiência técnica do operador.

O aprendizado de máquina (ML) pode ser caracterizado como algoritmo capaz de reconhecer padrões em dados brutos, fazer previsões e auxiliar na tomada de decisões subjetivas. Contudo, o aprendizado profundo (DL – *Deep Learning*) é uma subdivisão do ML, enquanto o ML trabalha com conjuntos de dados pequenos, o DL utiliza grandes volumes de dados (*big data*). Além disso, o DL foca na resolução de problemas de ponta a ponta (*end-to-end*) e processa dados em múltiplas camadas sucessivas e simultâneas, ao passo que o ML adota técnicas de divisão e gerenciamento de problemas e processa dados em camada única.

Dentre as ferramentas de aprendizado profundo (DL), as redes neurais convolucionais (CNN - *Convolutional Neural Network*) destacam-se como uma das mais populares e eficazes para tarefas de classificação. Sua principal vantagem é a capacidade de aprender automaticamente a partir de imagens de entrada (*input*) sem a necessidade de extração manual de características (Hinton et al., 2006). Porém, a CNN tradicional exige grande volume de dados de imagem para treinamento a partir do zero (Krizhevsky et al., 2017). Para contornar essa limitação, a técnica de aprendizado por transferência (TL - *Transfer Learning*) tem sido amplamente utilizada, permitindo que modelos pré-treinados sejam aplicados em novos problemas. Entre os modelos de arquitetura CNN mais populares estão o VGG16 (Simonyan & Zisserman, 2015) e o Inception ResNet (Szegedy et al., 2016), os quais utilizam essa abordagem para resolver desafios de classificação de imagens.

O modelo VGG16 (*VGG - Visual Geometry Group*), vencedor da competição ImageNet (Krizhevsky et al., 2017), representa um avanço em relação ao AlexNet (Krizhevsky et al., 2012) ao adotar filtros menores (*kernel* 3×3) em substituição aos maiores (*kernel* 5×5). Essa estratégia permite que uma pilha de dois filtros 3×3 seja equivalente a um filtro 5×5 , e três filtros 3×3 correspondem a um filtro 7×7 . Esse refinamento não linear aumenta a capacidade da CNN em aprender recursos de forma mais eficiente. No VGGNet (VGG19) um *kernel* convolucional 1×1 é utilizado para introduzir transformações não lineares sem alterar as dimensões de entrada (*input*) e saída (*output*), resultando em maior eficiência e redução de cálculos. O treinamento inicial é efetuado nas camadas inferiores e os pesos do ImageNet são utilizados para inicializar modelos complexos, acelerando a convergência do treinamento.

Outro modelo baseado em CNN amplamente utilizado é o Inception Network (Too et al., 2019). Embora as CNNs tenham bom desempenho com camadas profundas, elas enfrentam desafios como sobreajuste (*overfitting*), tamanhos de *kernel* menores e o desaparecimento de gradientes. As redes Inception superam essas limitações ao combinar filtros de diferentes tamanhos, como 1×1 , 3×3 e 5×5 , num mesmo nível, abordando a questão da largura, em vez de profundidade, na arquitetura da rede neural (Szegedy et al., 2017). A Inception ResNet V2 (Szegedy

et al., 2017) é uma evolução desse modelo, que reduz o custo computacional por meio de ajustes nos hiperparâmetros de seus três blocos principais.

Para mitigar o problema de sobreajuste em conjuntos de dados de imagem limitados, a técnica de aumento (*augmentation*) de imagem pode ser aplicada antes de alimentar as imagens nas arquiteturas Inception Network e VGG16 (Olsen et al., 2019). O aumento de imagem é uma técnica que amplia artificialmente conjuntos de dados existentes por meio de diversos métodos de processamento. Ele é crucial para a construção de classificadores robustos de imagens, principalmente quando há poucos dados de treinamento disponíveis (Ahsan et al., 2019). Métodos comuns incluem rotação aleatória, deslocamentos horizontais e verticais, cisalhamento, inversão, zoom e filtragem. Por exemplo, a rotação aleatória cria imagens giradas em diferentes ângulos (0 a 360°), enquanto o deslocamento move *pixels* em direções bidimensionais. A inversão inverte a linha e coluna da imagem, e o zoom foca em áreas específicas da imagem original. Técnicas de filtragem podem variar a iluminação, contraste e saturação, criando versões mais escuras ou brilhantes das imagens originais (Jia et al., 2017). A aplicação correta de técnicas de aumento de imagem é fundamental para melhorar o desempenho dos classificadores de imagem, mas escolhas inadequadas podem prejudicar os resultados. A biblioteca do TensorFlow (TensorFlow, s.d.) inclui uma ampla variedade de ferramentas pré-instaladas para aumento de imagem, além de permitir a adição de técnicas personalizadas.

A equipe do Google™ Brain lançou o TensorFlow em 2016 (Abadi et al., 2016), uma plataforma de código aberto (*open source*) para redes neurais de aprendizado profundo (DLNN – *Deep Learning Neural Network*). Essa biblioteca se destaca por sua eficácia, rapidez e precisão em aplicações industriais de inteligência artificial. Além disso, o TensorFlow pode ser utilizado em dispositivos móveis (*smartphones*) e internet das coisas (IoT – *Internet of Things*) por meio do TensorFlow Lite – *tflite* (Google Inc., s.d.), uma versão otimizada para fornecer resultados em tempo real. Sunil et al. (2021) demonstraram a aplicação deste modelo em dispositivos móveis para classificação de cortes de carne bovina, fornecendo informações rápidas e precisas sobre os cortes, tanto para a indústria de carnes quanto para os consumidores.

Os avanços da inteligência artificial nos últimos anos têm sido notáveis, com aplicações em diversas áreas. Algoritmos de processamento de imagens e aprendizado de máquina têm ganhado rápida aceitação em aplicações voltadas para a segurança de alimentos (*food safety*) e seguridade alimentar (*food security*), com destaque especial para o processamento de carnes (Shi et al., 2021; Wang & Li, 2024). Pesquisas indicaram que a AI tem grande potencial para classificar cortes de carne bovina (Sunil et al., 2021), detectar carne bovina DFD (Chmiel et al., 2012), carne suína PSE (Chmiel et al., 2016), mensurar o marmoreio de carnes bovina (Caridade et al., 2020) e suína (Liu et al., 2018ab; Sun et al., 2018), cor de carne suína (Sun et al., 2018) e de gordura bovina (Chen et al., 2010), maciez de carne bovina (Sun et al., 2012), bem como para detecção e desinfecção de contaminação na indústria de serviços alimentícios (Gorji et al., 2022). Além disso, a inteligência artificial (AI) utilizando aprendizado profundo (DL) também tem sido aplicada na classificação de ovelhas (Jwade et al., 2019) e de espécies em carnes (Al-Sarayreh et al., 2020).

3 CARCAÇAS

As carcaças, corpos de animais abatidos, eviscerados e processados, constituem matéria-prima essencial para o processamento de carnes. Avaliar suas características é crucial para determinar o valor de animais abatidos, e a classificação das carcaças desempenha papel fundamental para que as empresas de processamento obtenham matérias-primas de alta qualidade. No entanto, os sistemas de classificação variam entre países; enquanto alguns se baseiam na predição de rendimento, outros focam em atributos de qualidade. A detecção e predição acuradas desses aspectos são ferramentas vitais para que a indústria de processamento de carne minimize o desperdício ao longo da cadeia e atenda às demandas do mercado de maneira eficaz (Gardner et al., 2021).

Na maioria dos países europeus, a classificação de carcaças é realizada por especialistas que utilizam comparações visuais entre características individuais e critérios estabelecidos em cada país. Porém, esse processo é dependente do conhecimento, habilidades e ambiente do avaliador, tornando a classificação subjetiva (De La Iglesia et al., 2020). Por isso, a introdução de técnicas de

inteligência artificial (AI) é essencial para padronizar e melhorar as tarefas de classificação, previsão de rendimento e detecção de qualidade de carcaças.

A visão computacional (CVS) tem sido uma das soluções mais pesquisadas na avaliação de carcaças de bovinos, ovinos, suínos e aves, demonstrando grande utilidade (Pabiou et al., 2011). A previsão da composição, peso e rendimento de carcaças de cordeiros utilizando análise de imagens de vídeo (VIA) mostrou vantagens dessa tecnologia na previsão acurada do rendimento (Batista et al., 2021). Além disso, imagens tridimensionais (3D) têm sido utilizadas para prever o rendimento percentual de carne magra em bovinos com métodos supervisionados de aprendizado (Alempijevic et al., 2021).

Da mesma forma, Segura et al. (2021) investigaram a CVS na previsão da composição tecidual de vacas velhas; e, mais tarde, Segura et al. (2023) avaliaram também a viabilidade de dois sistemas de CVS na previsão do rendimento de carcaças bovinas, confirmando a capacidade dessa tecnologia em prever pesos pós-processamento, composições de tecido e porcentagens de rendimento.

A combinação de algoritmos de aprendizado de máquina (ML) e técnicas de CVS tem se mostrado eficaz na classificação de carcaças. Chandraratne et al. (2007) utilizaram técnicas para extração de características de textura em imagens de cordeiros e empregaram redes neurais artificiais (ANN – *Artificial Neural Network*) para classificar carcaças, comparando seu desempenho com análise de função discriminante (DF – *Discriminant Function*). Os resultados demonstraram que a ANN superou o desempenho da DF.

Shahinfar et al. (2018) compararam nove algoritmos de aprendizado de máquina (ML), e demonstraram sucesso na previsão de características de carcaças em ovinos, com destaque para a floresta aleatória (RF – *Random Forest*). Entretanto, na última década houve avanços no desempenho e aplicação de redes neurais convolucionais profundas (DCNN – *Deep Convolutional Neural Networks*) para dados de imagens (Canziani et al., 2016). Gonçalves et al. (2021) aplicaram dois métodos de segmentação de imagens baseados em aprendizado profundo (DL), o Superpixel+CNN e o SegNet, e obtiveram 97% de precisão na segmentação de carcaças de diferentes espécies, contribuindo para melhora significativa na classificação das carcaças. Algoritmos de aprendizado profundo (DL) também

foram empregados na predição do rendimento de cortes de carcaças bovinas a partir de dados de animais associados a imagens, alcançando resultados comparáveis aos métodos tradicionais de ML (Matthews et al., 2022).

A combinação de análise de imagem (CVS), análise multivariada de dados por meio de regressão linear múltipla (MLR – *Multiple Linear Regression*) e aprendizado profundo (DL) mostrou-se eficaz na predição dos rendimentos de carcaças bovinas a partir de imagens digitais (Wakholi et al., 2022). Os modelos demonstraram desempenho preditivo satisfatório, com coeficiente de determinação (R^2) superior a 0,84 e desvio médio (RMSE – *Root Mean Square Error*) inferior a 15% em relação à média dos valores de rendimentos modelados; principalmente, para a porcentagem de carne magra, com $R^2 = 0,90$ e RMSE = 1,98%. Esses resultados são melhores em relação à maioria dos sistemas de análise de imagem por vídeo (VIA), fornecendo base sólida para o desenvolvimento de um sistema *online* de classificação de carcaças bovinas e aprimorando os processos automatizados na linha de abate.

A avaliação da qualidade de carcaça envolve a análise de fatores que, após o abate, podem influenciar as características visuais e sensoriais da carne, tais como a cor e maciez (Delgado-Pando et al., 2021). Desse modo, a imagem espectral utilizada para a detecção de condenação de carcaças de aves geralmente se baseia em técnicas de visão de máquina (Chowdhury & Morey, 2020).

Outra abordagem envolve o uso de técnicas espectroscópicas combinadas com CVS para detectar contaminações na superfície de carcaças. Kang et al. (2016) desenvolveram sistema de detecção *online* para identificar contaminantes em carcaças de frango com base em imagens multiespectrais, alcançando precisão de 91,6%. De forma semelhante, Wu et al. (2017) conseguiram detectar sangue, bile e matéria fecal diluída na superfície de carcaças de frango, atingindo taxa de reconhecimento de 95% em nível regional.

A aplicação do CVS também pode trazer benefícios ambientais. DeOtte et al. (2010) utilizaram essa técnica para determinar de forma objetiva a limpeza de cabeças de bovinos esfoladas, permitindo estimar a quantidade mínima de água necessária para a purificação adequada das cabeças durante o processo de limpeza manual, contribuindo para a economia de água nos frigoríficos.

A identificação de doenças em carcaças de frangos de corte, aves e outros animais pode ser feita com o uso de CVS e modelos de redes neurais (NN – *Neural Network*), substituindo os métodos tradicionais de inspeção visual para a identificação de carcaças saudáveis (Chao et al., 2007; Yang et al., 2005; Yang et al., 2009). Além disso, Maes et al. (2023) apontaram que sistemas baseados em inteligência artificial estão sendo desenvolvidos para automatizar a avaliação de imagens de pleurisia em carcaças suínas após o abate, mas ainda exigem mais pesquisas para treinar redes neurais capazes de reconhecer e avaliar a pneumonia. Uma avaliação precisa e confiável é essencial para que os processadores de carne possam atender às expectativas dos consumidores.

4 CARNE E PRODUTOS CÁRNEOS

A qualidade da carne e seus derivados pode ser parcialmente avaliada pela análise de cor (Altmann et al., 2022). Essa análise pode ser realizada em imagens digitais utilizando softwares especializados de visão computacional (CVS), como o Optimas (Zheng et al., 2007) e o ImageJ (Meunier et al., 2020), bem como softwares gráficos amplamente disponíveis, como o Adobe Photoshop (Girolami et al., 2013).

Atributos de cor obtidos por CVS apresentaram correlação mais forte com a avaliação visual da cor da carne realizada por provadores do que as mensurações efetuadas por colorímetro Minolta (O'Sullivan et al., 2003). Diferenças significativas entre as cores de produtos cárneos (salsichas, presuntos e hambúrgueres) determinadas por CVS e por colorímetro Minolta também foram identificadas por Tomasevic et al. (2019). Os autores observaram que os atributos de cor gerados por CVS foram moderados a altamente similares às cores reais percebidas pelos painelistas. De acordo com Girolami et al. (2013), a tecnologia CVS demonstrou maior eficácia na replicação de cores reais em relação aos métodos tradicionais de colorimetria, pois, esses apresentam limitações decorrentes do reflexo de luz e irregularidade na superfície cárnea. Logo, a visão computacional (CVS) pode ser considerada um método mais preciso na mensuração da cor de carnes e de produtos cárneos, replicando-a de forma fiel e autêntica.

Chen et al. (2010) desenvolveram um modelo para classificar a qualidade da carne bovina baseado na cor da gordura, fator distintivo de qualidade na China. A

análise de imagem por CVS, juntamente com processamento de imagem e transformações vetoriais, permitiu classificar a cor da gordura bovina com 97,4% de precisão.

Kamruzzaman et al. (2016) exploraram a possibilidade de automação da CVS ao desenvolver sistema para monitoramento *online* da cor da carne vermelha (bovina, ovina e suína). Os resultados indicaram que a imagem hiperespectral (HS) possui potencial para ser utilizada na avaliação rápida da cor de carnes pela indústria, com altos coeficientes de determinação (r^2 de 0,82 a 0,97) nos modelos desenvolvidos.

Diversas tentativas também foram feitas para utilizar o CVS na detecção de anomalias de qualidade na carne, tais como a carne pálida, macia e exsudativa (PSE – *Pale, Soft, Exudative*). Identificar esses defeitos é um processo complexo, que normalmente envolve a mensuração de pH, luminosidade (L^*), capacidade de retenção de água (CRA) e condutividade elétrica. Esses métodos são trabalhosos e demorados, sendo pouco práticos para aplicação *online* em ambientes industriais. Nesse contexto, o desenvolvimento de métodos rápidos e não destrutivos, aplicáveis *online*, é altamente demandado.

Chmiel et al. (2011) demonstraram a viabilidade do uso de valores V/B (modelo HSV/HSB), L (modelo HSL) e R, G, B (modelo RGB) para detectar defeitos PSE no músculo *longissimus* de suínos por CVS. Em estudo posterior, Chmiel & Słowiński (2016) descobriram que o CVS podia ser utilizado para detectar amostras de carne PSE e carne escura, firme e seca (DFD – *Dark, Firm, Dry*), bem como para classificar a carne suína em diferentes grupos de qualidade. Contudo, observaram que a técnica não era eficaz para diferenciar entre carne suína vermelha, macia e exsudativa (RSE - *Red, Soft, Exudative*) de vermelha, firme e normal (RFN – *Red, Firm, Normal*). A maior precisão na classificação foi alcançada com os atributos de cor HSL, com 81,7% de exatidão. Logo, Chmiel & Słowiński (2016) concluíram que o CVS pode ser utilizado para análise rápida da qualidade da carne suína *m. longissimus lumborum* em condições industriais. No entanto, quando aplicado ao músculo semimembranoso de suínos, caracterizado por alta instabilidade da cor superficial, o método apresentou limitações na detecção de carne PSE (Chmiel et al., 2016).

A presença de veias e pele vermelha na superfície de presuntos curados a seco é outro defeito de qualidade detectável com base em mensurações de cor. Lopes et al. (2020) propuseram análise de imagem em dois estágios, aumentando a precisão na predição desse defeito de 63% para 88%.

A gordura e o marmoreio exercem uma influência crucial na qualidade sensorial da carne e seus derivados, afetando diretamente características como maciez, suculência e sabor. Tradicionalmente, o teor de gordura é avaliado por métodos de extração (ex.: *Soxhlet*), reconhecidos pela precisão, mas que apresentam desvantagens, como a natureza destrutiva, demorada e necessidade de solventes. Contudo, esses métodos podem ser substituídos pelo sistema de visão computacional (CVS), uma vez que há correlação linear entre o teor de gordura na carne e a proporção de superfície ocupada pela gordura na imagem capturada (Modzelewska-Kapituła & Cierach, 2012; Lambe et al., 2021;).

Diversos pesquisadores (Chen & Qin, 2008; Du et al., 2008) têm se dedicado ao desenvolvimento de algoritmos para a segmentação automática de imagens com o objetivo de extrair depósitos de gordura. Do mesmo modo, redes neurais convolucionais profundas (DCNN) foram aplicadas a imagens de ultrassom para estimar a gordura intramuscular em suínos (Kvam & Kongsro, 2017).

Apesar da eficácia, há diferenças entre resultados obtidos por CVS e métodos químicos. Os métodos químicos (ex.: hidrólise ácida) podem extrair diferentes frações de ácidos graxos no músculo, influenciando a concentração de gordura extraída e podendo também coextrair substâncias que não são lipídios (Lambe et al., 2021). A principal diferença entre esses métodos reside no princípio de determinação do conteúdo de gordura: enquanto os métodos químicos baseiam-se na massa de gordura, o CVS calcula a gordura baseado na área ocupada nas imagens de cortes musculares transversais. Além disso, o tecido conjuntivo, que possui coloração semelhante a gordura, pode ser erroneamente identificado como gordura pelo CVS, exigindo, assim, a construção de modelos de regressão para melhorar a precisão da predição do teor de gordura (Stewart et al., 2021ab). A exatidão dessa predição é influenciada pelo método de aquisição das imagens, pela modelagem, pelo tipo de carne e pela orientação das fibras musculares.

Meunier et al. (2020) demonstraram que o CVS é capaz de prever o teor de gordura intramuscular em carcaças bovinas com precisão de 90%. Anderson et al. (2018) utilizaram tomografia computadorizada para prever a gordura intramuscular em músculos *longissimus thoracis et lumborum* de bovinos, encontrando diferenças significativas na eficácia preditiva entre esses músculos. Por outro lado, Dixit et al. (2021) utilizaram dados de imagens hiperespectrais para prever a gordura intramuscular e o valor de pH em carne de várias espécies, obtendo altos coeficientes de determinação, tanto na calibração quanto na predição, para modelos que consideraram variações na composição química e estrutural da carne, bem como nas condições experimentais. Esses resultados apontam para o potencial de desenvolvimento de sistemas não invasivos para avaliação da qualidade da carne em plantas de processamento, o que pode reduzir custos no desenvolvimento de novos modelos aplicáveis a diferentes tipos de carne e processos.

Além disso, a utilização de CVS em conjunto com câmeras digitais para determinar o teor de gordura também foi explorada em suínos (Liu et al., 2018ab) e aves (Chmiel et al., 2011), com variações nos resultados dependendo do tipo de músculo e cor da carne. A precisão dessas predições pode ser limitada em carnes com pouca diferença de cor entre gordura e tecido muscular, levando a necessidade de explorar imagens de ressonância magnética ou tomografia computadorizada para melhorar a distinção entre esses tecidos.

A aplicação de imagens de ultrassom para prever o teor de gordura também tem sido testada em bovinos vivos (Fiore et al., 2020), contribuindo para a melhoria da qualidade da carne e eficiência no manejo de alimentação. Porém, a aplicação dessa técnica em suínos ainda enfrenta desafios, pois a qualidade das imagens ultrassonográficas é afetada pela espessura de gordura dorsal.

Em países como EUA, Japão e Austrália, o marmoreio é um critério essencial para a classificação de carne bovina, sendo tradicionalmente avaliado visualmente por especialistas treinados. Todavia, o uso de CVS tem se mostrado promissor para a automatização e precisão dessa avaliação, permitindo a quantificação de características do marmoreio, como proporção de gordura e tamanho dos depósitos de gordura (Giaretta et al., 2018; Caridade et al., 2020). Além disso, técnicas

avançadas como a ressonância magnética e a imagem microscópica têm sido exploradas para caracterizar a distribuição de gordura e sua correlação com o perfil de ácidos graxos, oferecendo novas perspectivas para a avaliação da composição de ácidos graxos na carne (Nakahashi et al., 2008; Ma & Sun, 2020). Assim, métodos instrumentais rápidos, precisos, econômicos e de fácil implementação para determinar o teor de gordura intramuscular são particularmente vantajosos em plantas de processamento de carne, pois permitem a avaliação da qualidade de carne e sua integração com programas de melhoramento genético.

Imagens hiperespectrais (HS - *Hyperspectral*) no infravermelho próximo (NIR - *Near Infrared*) e CVS também têm sido utilizadas para prever a composição química da carne, com resultados promissores para a avaliação simultânea de diversos constituintes químicos sem o uso de reagentes perigosos (Kamruzzaman et al., 2016; ElMasry et al., 2013). Além disso, a técnica tem potencial para determinar a capacidade de retenção de água na carne, fator importante para a classificação e identificação de músculos bovinos (ElMasry et al., 2011). Adicionalmente, sistemas de imagem Vis/NIR HS têm sido aplicados com sucesso para determinar o teor de metamioglobina em carne, o que é relevante para a avaliação da cor da carne (Yuan et al., 2020).

É possível prever com eficácia a maciez da carne utilizando parâmetros como cor, marmoreio e características texturais obtidas a partir de imagens (CVS), alcançando coeficiente de determinação (r^2) de 0,70 (Li et al., 1999). No entanto, a análise isolada dos parâmetros de cor e marmoreio apresenta limitações na predição da maciez, pois, explicam apenas 30% da variabilidade observada na maciez da carne (Li et al., 1999). Adicionalmente, a textura das imagens do músculo bovino foi correlacionada com as propriedades das fibras musculares, seu tamanho e distribuição, permitindo inferências sobre a maciez da carne (Li et al., 1999).

Em outra pesquisa, Li et al. (2001) utilizaram exclusivamente parâmetros de textura derivados de imagens, após conversão de RGB para HSI, na predição da maciez em carne bovina. O estudo focou nas diferenças do canal S em imagens de carnes macias e duras; e, concluiu que a análise da textura de imagens de carne

crua poderia prever se a carne seria macia ou dura após o tratamento térmico, embora essa análise não permitisse determinar graus específicos de maciez.

A maciez da carne também pode ser predita com base na estrutura e distribuição do tecido conjuntivo intramuscular. Del Moral et al. (2007) utilizaram imagens microscópicas coradas e desenvolveram algoritmos de processamento de imagem que possibilitaram a medição automática e precisa do conteúdo de tecido conjuntivo intramuscular, superando as mensurações efetuadas por métodos morfométricos convencionais. O estudo demonstrou que o conteúdo e a distribuição espacial do tecido conjuntivo afetam a aparência da carne bovina e, conseqüentemente, a textura das imagens, fornecendo informações valiosas para a estimativa da qualidade sensorial da carne.

Sifre-Maunier et al. (2006) observaram que o tecido conjuntivo intramuscular desempenha um papel crucial na maciez da carne, especialmente quando o tratamento pós-abate garante o amaciamento *post-mortem* completo, associado à quebra de proteínas miofibrilares. El Jabri et al. (2010) determinaram atributos do tecido conjuntivo em imagens de amostras de carne bovina coletadas sob luz ultravioleta (UV) e visível (VIS), e, utilizando técnicas estatísticas, estabeleceram uma relação entre a distribuição do tecido conjuntivo intramuscular caracterizada por CVS e maciez da carne avaliada por painelistas treinados. Os autores encontraram que, utilizando um modelo de regressão linear múltipla baseado em parâmetros de imagens tiradas sob iluminação visível e UV, os atributos do tecido conjuntivo permitiram prever a maciez da carne ($r^2 = 0,89$), assim como os teores de colágeno ($r^2 = 0,82$) e gordura ($r^2 = 0,91$).

Basset et al. (2000) utilizaram CVS para classificar carne de acordo com a raça, idade do animal e tipo de músculo, além de examinar a relação entre a textura da imagem e a composição química da carne bovina. Eles descobriram que havia possibilidade de segregação adequada das amostras com base na textura da imagem e observaram correlação linear entre as características de textura das imagens e os parâmetros físico-químicos das amostras.

Modelos para predição da força de cisalhamento (WBS - *Warner-Bratzler Shear force*), aceitabilidade, palatabilidade e classificação da carne como macia ou dura foram desenvolvidos a partir de parâmetros de cor, marmoreio e textura de

imagem (Jackman et al., 2008; Jackman et al., 2009abcd). Os autores conseguiram prever a aceitabilidade da carne bovina com coeficiente de determinação (r^2) de 0,82. Foi constatado também que as características de textura das imagens em escala 1:1 forneciam informações mais úteis sobre o sabor do que as imagens ampliadas 6,4 vezes, que, por sua vez, eram mais eficazes na predição da palatabilidade com base em parâmetros de cor e marmoreio.

Grimes et al. (2007) desenvolveram modelo para predição da maciez de carne bovina com precisão de 96% a partir de imagens HS. Já Naganathan et al. (2008) utilizaram dados obtidos por meio da análise de imagens VIS/NIR HS, obtendo modelos que predisseram a maciez das amostras com precisão de 94%.

Ranasinghesagara et al. (2010) mostraram que a maciez da carne bovina pode ser estimada utilizando informações obtidas por CVS de reflectância de superfície bidimensional, identificando correlação (r^2) de 0,46 a 0,50 entre os parâmetros ópticos mensurados nas imagens e valores de WBS. Finalmente, Caballero et al. (2018ab) evidenciaram a utilidade da CVS baseada em imagens de ressonância magnética para a predição da qualidade sensorial de lombos de porco curados a seco, concluindo que o algoritmo de análise de imagem proposto, juntamente com técnicas preditivas, pode ser uma ferramenta eficaz para as indústrias de carne caracterizarem seus produtos de forma não destrutiva.

A tecnologia de visão computacional (CVS) permite mensurar a área superficial e o volume de produtos cárneos inteiros (Du & Sun, 2006; Modzelewska-Kapituła & Wróblewski, 2014). Ao mensurar a superfície da carne antes e após o tratamento térmico, é possível avaliar o grau de encurtamento térmico, um fator que influencia a transferência de calor durante o resfriamento de produtos cárneos, afetando sua eficiência de produção, suculência e segurança microbiológica.

Estudos realizados por Zheng et al. (2006, 2007) aplicaram a técnica CVS para determinar o volume de cortes de carne bovina, a fim de avaliar o encurtamento durante o resfriamento pós-tratamento térmico. Como os cortes tratados apresentavam formas elipsoidais irregulares, foram realizadas mensurações dos eixos principais e secundários antes e após o resfriamento, combinando a forma elipsoidal com a superfície dos elementos. Para calcular o volume e a superfície dessas amostras, as imagens foram divididas em várias

seções transversais, cada uma considerada como um disco cilíndrico. A partir desses resultados, foram desenvolvidos modelos lineares ($r^2 > 0,99$) para prever a contração dos eixos principais e auxiliares, bem como o volume e a área superficial dos cortes de carne bovina.

Du & Sun (2006) investigaram métodos automáticos precisos para determinar a área superficial e o volume de presuntos utilizando análise de imagens (CVS). Eles utilizaram algoritmos de processamento de imagem, como segmentação, redução de ruído, detecção de bordas e transformações matemáticas, para estimar essas dimensões com precisão. Descobriu-se que o método de divisão proporcionava uma estimativa mais precisa da área superficial e do volume de presuntos, com erro de apenas 1,79% em comparação a 4,96% pelo método de derivada.

Além disso, o CVS foi empregado para estudar os efeitos do processo de congelamento e descongelamento na qualidade da carne. Uttaro & Aalhus (2007) examinaram como esses processos influenciam a distribuição de salmoura em cortes de carne, utilizando corante azul como marcador. A análise de imagens permitiu concluir que nem o congelamento e nem o descongelamento afetaram significativamente a distribuição de salmoura na carne.

Outro exemplo de uso do CVS foi demonstrado por Ruedt et al. (2020), os quais avaliaram a iridescência superficial em presuntos cozidos. Utilizando métodos de segmentação por limiarização (*thresholding*) e agrupamento (*k-means clustering*), a análise de imagem mostrou concordância quase perfeita ($\kappa = 0,800$, $p = 0,001$) com a avaliação sensorial convencional, sugerindo que o CVS pode ser uma alternativa viável para a quantificação da iridescência em produtos cárneos.

Além de mensurar superfícies em imagens macroscópicas, o CVS também é aplicado em imagens microscópicas. Ele permite mensurar a área ocupada por fibras de colágeno, o comprimento de sarcômero e caracterizar os diferentes tipos de fibras musculares em termos relativos (%), diâmetro, área e percentual de área (Mora et al., 2015; Bersani-Amado et al., 2016; Monteschio et al., 2019). Esses estudos, realizados com microscopia de luz, eliminam a necessidade de microscopia eletrônica, tornando as análises mais acessíveis. As mensurações feitas com CVS contribuem para compreensão mais profunda da ultraestrutura do

tecido muscular, o que, por sua vez, pode esclarecer questões relacionadas à maciez da carne.

Na ciência e indústria de alimentos, há um esforço contínuo para desenvolver ferramentas que permitam avaliação rápida e objetiva do frescor de alimentos, preferencialmente *online*. Carne e produtos cárneos são suscetíveis à deterioração devido a reações químicas, como processos enzimáticos e oxidação, além de crescimento microbiológico, que alteram cor, aroma, textura e sabor, comprometendo a segurança e valor nutricional dos produtos. Esses processos podem ocorrer antes que os produtos cheguem ao consumidor. Nesse contexto, Arsalane et al. (2018; 2019) conduziram estudos visando desenvolver ferramenta para avaliação do frescor de carne bovina baseado em características de cor e textura superficial, extraídas do canal S de imagens RGB convertidas para o espaço de cores HSI.

A inteligência artificial tem sido amplamente aplicada na inspeção de qualidade em carnes, associada a tecnologias espectrais (imagem multiespectral, hiperespectral e espectral no infravermelho próximo), cromatográficas (cromatografia gasosa ultrarrápida), e sensores (nariz eletrônico e língua eletrônica). Tais combinações permitem a classificação e predição de aspectos cruciais, como o frescor e outras qualidades da carne. Essa crescente integração de tecnologias e modelagem preditiva em processos de avaliação da qualidade de carnes reflete tendência em direção a métodos mais eficientes, precisos e menos invasivos, com potencial para transformar as práticas industriais e melhorar a qualidade dos produtos cárneos disponíveis ao consumidor.

5 AUTOMAÇÃO E APLICAÇÕES INDUSTRIAIS

A automação e a inteligência artificial no processamento de carne têm sido amplamente aplicadas no processamento primário. Técnicas de inteligência artificial estão sendo utilizadas no monitoramento de qualidade da carne em fábricas de processamento. Blagoveshchenskiy et al. (2020) analisaram as limitações dos métodos tradicionais de avaliação da qualidade e propuseram o uso de bancos de dados inteligentes e sistemas especialistas para monitorar e prever indicadores de qualidade do produto. Os autores desenvolveram um banco de

dados para monitoramento de parâmetros de qualidade, integrando sistema especialista inteligente (*intelligence expert system*). Além disso, Yi et al. (2010) empregaram redes neurais de função de base radial (RBFNN – *Radial Basis Function Neural Network*) e técnicas de processamento de dados *fuzzy* para criar um sistema de monitoramento da produção de carne suína. Este sistema foi capaz de monitorar, adquirir e trocar dados de produção em tempo real, melhorando o controle de qualidade no processamento.

Inovações como tecnologia óptica e AI podem aumentar a durabilidade e a eficiência das ferramentas de corte (Mason et al., 2022), oferecendo suporte à tomada de decisões e análise de dados, o que é particularmente interessante para o desenvolvimento de facas inteligentes. Esper et al. (2021) também destacaram sistemas automatizados, como o AiRA[®] (Frontmatec[™]) e o Hamdas-RX[®] (Mayekawa[™]), os quais incorporam diferentes graus de automação e tecnologias de visão para tarefas como corte e desossa em frigoríficos, promovendo inovações significativas para processadores de carne.

Um alto nível de automação foi alcançado no processamento de carnes, especialmente para tarefas repetitivas. Nas etapas iniciais da linha de abate houve avanços significativos na automação. Exemplo claro dessa evolução é o sistema automatizado de corte de carne, que combina *scanner* a laser para gerar imagens 3D com lâmina rotativa de alta velocidade controlada por computador. Esse sistema utiliza visão computacional e inteligência artificial para realizar até 700 cortes por minuto com precisão de $\pm 0,5\%$, superando a precisão do trabalho manual e melhorando a eficiência, velocidade e higiene. Outros exemplos incluem sistemas de corte de carcaças bovinas, que utilizam sensores para criar imagens detalhadas da carcaça e realizam cortes controlados por computador, e a tecnologia de corte com jato de água para filés de peixe, em que algoritmos determinam o padrão ideal de corte, minimizando o desperdício (Barbut, 2020).

O VIAscan[®], baseado em CVS, foi introduzido na Nova Zelândia para estimar automaticamente o rendimento de carne magra em cordeiros (Jopson et al., 2009; Jay et al., 2014). O CVS também tem sido implementado com sucesso em abatedouros de aves, suínos e bovinos, como o DVC[™] - *Digital Vision Classification* (Machinevision[®], Holanda) para a classificação de aves inteiras e identificação de

defeitos de qualidade, o AutoFom III™ (Frontmatec®, Dinamarca) para classificação de carcaças suínas e rendimento de corte primários e comerciais (Masferrer et al., 2018), e o IRIS™ - *Intelligent Reporting, Inspection & Selection* (Marel®, Islândia), que avalia carcaças inteiras e suas porções anatômicas, detectando defeitos como asas quebradas, hematomas, manchas fecais e danos à pele.

A completa automação no processamento de carnes aponta para um futuro inevitável, impulsionado pela evolução contínua das tecnologias e múltiplas frentes de inovação. A colaboração entre humanos e robôs (Demir et al., 2019), a crescente adoção das células de fábrica de carne MFCs - *Meat Factory Cells* (Alvseike et al., 2018; Manko et al., 2024) e a expansão dos algoritmos de inteligência artificial (AI) são tendências fundamentais que definirão o desenvolvimento da automação e inteligência nesse setor.

6 CONSIDERAÇÕES FINAIS

A inteligência artificial (AI) apresenta enorme potencial para revolucionar a indústria de processamento de carnes, otimizando a produção e aumentando a eficiência operacional. A automação de processos repetitivos e a aplicação de algoritmos de aprendizado de máquina têm elevado a precisão e reduzido custos, resultando em técnicas de produção mais eficazes. Todavia, a adoção da AI ainda enfrenta desafios significativos, como a necessidade de flexibilidade nas linhas de produção e a complexidade intrínseca das operações, além do impacto de fatores ambientais na eficácia dos sensores e equipamentos.

Outro aspecto crítico é o alto custo associado à implementação de tecnologias avançadas, os quais requerem investimentos substanciais em equipamentos e na formação de profissionais qualificados, dificultando o acesso para pequenos processadores. Apesar disso, a evolução constante dos algoritmos e a redução de custo dos sensores podem facilitar a integração da automação inteligente no setor.

Pesquisas sobre a avaliação da qualidade da carne enfrentam dificuldades relacionadas à obtenção de dados de alta qualidade e à integração de diferentes tecnologias de AI para inspeção. Para aprimorar a detecção de qualidade, é crucial

desenvolver sistemas abrangentes que utilizem dados em tempo real e combinem múltiplos métodos de inspeção.

Em síntese, embora a aplicação da AI no processamento de carne apresente um futuro promissor, é fundamental superar os desafios de custos, flexibilidade e qualidade dos dados. Acreditamos que, com inovações contínuas, a AI pode desempenhar papel cada vez mais relevante na indústria, promovendo eficiência, segurança e controle de qualidade mais robusto e confiável.

REFERÊNCIAS

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., et al. (2016). TensorFlow: large-scale machine learning on heterogeneous distributed systems. *Computer Science*. <https://doi.org/10.48550/arXiv.1603.04467>
- Ahsan, M., Gomes, R., and Denton, A. (2019). Application of a convolutional neural network using transfer learning for tuberculosis detection. *2019 IEEE International Conference on Electro Information Technology (EIT)*, 427–433. <https://doi.org/10.1109/EIT.2019.8833768>
- Alempijevic, A., Vidal-Calleja, T., Falque, R., Quin, P., Toohey, E., Walmsley, B., McPhee, M. (2021) Lean meat yield estimation using a prototype 3D imaging approach. *Meat Science*, 181, 108470. <https://doi.org/10.1016/j.meatsci.2021.108470>
- Al-Sarayreh, M., Reis, M.M., Yan, W.Q., Klette, R. (2020). Potential of deep learning and snapshot hyperspectral imaging for classification of species in meat. *Food Control*, 117, 107332. <https://doi.org/10.1016/j.foodcont.2020.107332>
- Altmann, B.A., Gertheiss, J., Tomasevic, I., Engelkes, C., Glaesener, T., Meyer, J., Mörlein, D. (2022). Human perception of color differences using computer vision system measurements of raw pork loin. *Meat Science*, 188, 108766. <https://doi.org/10.1016/j.meatsci.2022.108766>
- Alvseike, O., Prieto, M., Torkveen, K., Ruud, C., Nesbakken, T. (2018) Meat inspection and hygiene in a meat factory cell – an alternative concept. *Food Control*, 90, 32-39. <https://doi.org/10.1016/j.foodcont.2018.02.014>
- Anderson, F., Cook, J., Williams, A., Gardner, G.E. (2018). Computed tomography has improved precision for prediction of intramuscular fat percent in the *M. longissimus thoracis et lumborum* in cattle compared to manual grading. *Meat Science*, 145, 425–430. <https://doi.org/10.1016/j.meatsci.2018.07.025>
- Arsalane, A., Barbri, N., Tabyaoui, A., Klilou, A., Rhofir, A., Halimi, A. (2018). An embedded system based on DSP platform and PCA-SVM algorithms for rapid beef meat freshness prediction and identification. *Computers and Electronics in Agriculture*, 152, 385–392. <https://doi.org/10.1016/j.compag.2018.07.031>
- Arsalane, A., El Barbri, N., Tabyaoui, A., Klilou, A., Rhofir, K. (2019). The assessment of fresh and spoiled beef meat using a prototype device based on GigE vision camera and DSP. *Journal of Food Measurement and Characterization*, 13(3), 1730–1738. <https://doi.org/10.1007/s11694-019-00090-y>
- Balage, J.M., Amigo, J.M., Antonelo, D.S., Mazon, M.R., Luz e Silva, S. da (2018). Shear force analysis by core location in *longissimus* steaks from Nellore cattle using hyperspectral images – a feasibility study. *Meat Science*, 143, 30–38. <https://doi.org/10.1016/j.meatsci.2018.04.003>
- Barbut, S. (2020). Meat Industry 4.0: A distant future? *Animal Frontiers*, 10(4), 38–47. <https://doi.org/10.1093/af/vfaa038>

- Basset, O., Buquet, B., Abouelkaram, S., Delachartre, P., Culioli, J. (2000). Application of texture image analysis for the classification of bovine meat. *Food Chemistry*, 69, 437–445. [https://doi.org/10.1016/S0308-8146\(00\)00057-1](https://doi.org/10.1016/S0308-8146(00)00057-1)
- Batista, A.C., Santos, V., Afonso, J., Guedes, C., Azevedo, J., Teixeira, A., Silva, S. (2021). Evaluation of an image analysis approach to predicting primal cuts and lean in light lamb carcasses. *Animals*, 11(5), 1368. <https://doi.org/10.3390/ani11051368>
- Bersani-Amado, L.E., Dantas, J.A., Damião, M.J., Rocha, B.A., Besson, J.C.F., Bastos, R.L., Cuman, R.K.N. (2016). Involvement of cytokines in the modulation and progression of renal fibrosis induced by unilateral ureteral obstruction in C57BL/6 mice: effects of thalidomide and dexamethasone. *Fundamental and Clinical Pharmacology*, 30, 35–46. <https://doi.org/10.1111/fcp.12162>
- Blagoveshchenskiy, I.G., Blagoveshchenskiy, V.G., Besfamilnaya, E.M., Sumerin, V.A. (2020) Development of databases of intelligent expert systems for automatic control of product quality indicators. *Journal of Physics: Conference Series*, 1705(1), 012019. <https://doi.org/10.1088/1742-6596/1705/1/012019>
- Bohr, A., & Memarzadeh, K. (2020). The rise of artificial intelligence in healthcare applications. *Artificial Intelligence in Healthcare*, 25–60. <https://doi.org/10.1016/B978-0-12-818438-7.00002-2>
- Caballero, D., Antequera, T., Caro, A., Amigo, J.M., Ersbøll, B.K., Dahl, A.B., P´erez- Palacios, T. (2018a). Analysis of MRI by fractals for prediction of sensory attributes: A case study in loin. *Journal of Food Engineering*, 227, 1–10. <https://doi.org/10.1016/j.jfoodeng.2018.02.005>
- Caballero, D., Caro, A., Dahl, A.B., Ersbøll, B.K., Amigo, J.M., P´erez-Palacios, T., Antequera, T. (2018b). Comparison of different image analysis algorithms on MRI to predict physico-chemical and sensory attributes of loin. *Chemometrics and Intelligent Laboratory Systems*, 180, 54–63. <https://doi.org/10.1016/j.chemolab.2018.04.008>
- Canziani, A., Paszke, A., Culuiello, E. (2016). An analysis of deep neural network models for practical applications. *Computer Vision and Pattern Recognition*. <https://doi.org/10.48550/arXiv.1605.07678>
- Caridade, C. M. R., Pereira, C. D., Pires, A. F., Marnotes, N. G., & Viegas, J. F. (2020). Image analysis as a tool for beef grading. *Computer methods in biomechanics and biomedical Engineering: Imaging & Visualization*. <https://doi.org/10.1080/21681163.2020.1776159>
- Chamara, R.M.S.R., Senevirathne, S.M.P., Samarasinghe, S.A.I.L.N., Premasiri, M.W.R.C., Sandaruwani, K.H.C., Dissanayake, D.M.N.N., De Silva, S.H.N.P., Ariyaratne, W.M.T.P., Marambe, B. (2020) Role of artificial intelligence in achieving global food security: a promising technology for future. *Sri Lanka Journal of Food and Agriculture*, 6(2), 43-70. <https://doi.org/10.4038/sljfa.v6i2.88>
- Chandraratne, M.R., Kulasiri, D., Samarasinghe, S. (2007). Classification of lamb carcass using machine vision: comparison of statistical and neural network analyses. *Journal of Food Engineering*, 82(1), 26–34. <https://doi.org/10.1016/j.jfoodeng.2007.01.003>

- Chao, K., Yang, C.C., Chen, Y.R., Kim, M.S., Chan, D.E. (2007). Hyperspectral-multispectral line-scan imaging system for automated poultry carcass inspection applications for food safety. *Poultry Science*, 86(11), 2450–2460. <https://doi.org/10.3382/ps.2006-00467>
- Chen, K., & Qin, C. (2008). Segmentation of beef marbling based on vision threshold. *Computers and Electronics in Agriculture*, 62, 223–230. <https://doi.org/10.1016/j.compag.2008.01.002>
- Chen, K., Sun, X., Qin, C., Tang, X. (2010). Color grading of beef fat by using computer vision and support vector machine. *Computers and Electronics in Agriculture*, 70, 27–32. <https://doi.org/10.1016/j.compag.2009.08.006>
- Chmiel, M, Slowinski, M, Dasiewicz, Krzysztof, and Florowski, T (2012). Application of a computer vision system to classify beef as normal or dark, firm, and dry. *Journal of Animal Science*, 90, 4126–30. <https://doi.org/10.2527/jas.2011-5022>
- Chmiel, M., & Słowiński, M. (2016). The use of computer vision system to detect pork defects. *LWT - Food Science and Technology*, 73, 473–480. <https://doi.org/10.1016/j.lwt.2016.06.054>
- Chmiel, M., Słowiński, M., Dasiewicz, K. (2011). Application of computer vision systems for estimation of fat content in poultry meat. *Food Control*, 22, 1424–1427. <https://doi.org/10.1016/j.foodcont.2011.03.002>
- Chmiel, M., Słowiński, M., Dasiewicz, K., & Florowski, T. (2016). Use of computer vision system (CVS) for detection of PSE pork meat obtained from *m. semimembranosus*. *LWT - Food Science and Technology*, 65, 532–536. <https://doi.org/10.1016/j.lwt.2015.08.021>
- Chowdhury, E.U., Morey, A. (2020). Application of optical technologies in the US poultry slaughter facilities for the detection of poultry carcass condemnation. *British Poultry Science*, 61(6), 646–652. <https://doi.org/10.1080/00071668.2020.1792833>
- De La Iglesia, D.H., González, G.V., García, M.V., Rivero, A.J.L., De Paz, J.F. (2020). Non-invasive automatic beef carcass classification based on sensor network and image analysis. *Future Generation Computer Systems*, 113, 318–328. <https://doi.org/10.1016/j.future.2020.06.055>
- Del Moral, F.G., O'Valle, F., Masseroli, M. (2007). Image analysis application for automatic quantification of intramuscular connective tissue in meat. *Journal of Food Engineering*, 81, 33–41. <https://doi.org/10.1016/j.jfoodeng.2006.07.017>
- Delgado-Pando, G., Allen, P., Troy, D.J., McDonnell, C.K. (2021). Objective carcass measurement technologies: latest developments and future trends. *Trends in Food Science & Technology*, 111, 771–782. <https://doi.org/10.1016/j.tifs.2020.12.016>
- Demir, K.A., Döven, G., Sezen, B. (2019). Industry 5.0 and human-robot co-working. *Procedia Computer Science*, 158, 688–695. <https://doi.org/10.1016/j.procs.2019.09.104>
- DeOtte, R.E., Spivey, K.S., Galloway, H.O., Lawrence, T.E. (2010). Conservation of water for washing beef heads at harvest. *Meat Science*, 84, 371–376. <https://doi.org/10.1016/j.meatsci.2009.09.004>

- 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>
- Du, A. (2023). English speech recognition based on deep machine learning algorithm. In: Hung, J.C., Chang, J.W., Pei, Y. (eds) Innovative Computing Vol 2 - Emerging Topics in Future Internet. IC 2023. Lecture Notes in Electrical Engineering, vol 1045. Springer, Singapore. https://doi.org/10.1007/978-981-99-2287-1_28
- Du, C.J., & Sun, D.W. (2006). Estimating the surface area and volume of ellipsoidal ham using computer vision. *Journal of Food Engineering*, 73, 260–268. <https://doi.org/10.1016/j.jfoodeng.2005.01.029>
- Du, C.J., Sun, D.W., Jackman, P., Allen, P. (2008). Development of a hybrid image processing algorithm for automatic evaluation of intramuscular fat content in beef *m. longissimus dorsi*. *Meat Science*, 80, 1231–1237. <https://doi.org/10.1016/j.meatsci.2008.05.036>
- El Jabri, M., Abouelkaram, S., Damez, J.L., Berge, P. (2010). Image analysis study of the perimysial connective network, and its relationship with tenderness and composition of bovine meat. *Journal of Food Engineering*, 96, 316–322. <https://doi.org/10.1016/j.jfoodeng.2009.08.006>
- ElMasry, G., Sun, D.W., Allen, P. (2011). Non-destructive determination of water-holding capacity in fresh beef by using NIR hyperspectral imaging. *Food Research International*, 44, 2624–2633. <https://doi.org/10.1016/j.foodres.2011.05.001>
- ElMasry, G., Sun, D.W., Allen, P. (2013). Chemical-free assessment and mapping of major constituents in beef using hyperspectral imaging. *Journal of Food Engineering*, 117, 235–246. <https://doi.org/10.1016/j.jfoodeng.2013.02.016>
- Esmaeily, R., Razavi, M.A., Razavi, S.H. (2024) A step forward in food science, technology and industry using artificial intelligence. *Trends in Food Science & Technology*, 143, 104286. <https://doi.org/10.1016/j.tifs.2023.104286>
- Esper, I.D.M., From, P.J., Mason, A. (2021). Robotisation and intelligent systems in abattoirs. *Trends in Food Science & Technology*, 108, 214–222. <https://doi.org/10.1016/j.tifs.2020.11.005>
- FAO, IFAD, UNICEF, WFP and WHO. (2022) *The State of Food Security and Nutrition in the World 2022. Repurposing food and agricultural policies to make healthy diets more affordable*. Rome, FAO. <https://doi.org/10.4060/cc0639en>
- Fiore, E., Fabbri, G., Gallo, L., Morgante, M., Muraro, M., Boso, M., Giancesella, M. (2020). Application of texture analysis of b-mode ultrasound images for the quantification and prediction of intramuscular fat in living beef cattle: a methodological study. *Research in Veterinary Science*, 131, 254–258. <https://doi.org/10.1016/j.rvsc.2020.04.020>
- Gardner, G.E., Apps, R., McColl, R., Craigie, C.R. (2021). Objective measurement technologies for transforming the Australian & New Zealand livestock industries. *Meat Science*, 179, 108556. <https://doi.org/10.1016/j.meatsci.2021.108556>

- Giaretta, E., Mordenti, A.L., Canestrari, G., Brogna, N., Palmonari, A., Formigoni, A. (2018). Assessment of muscle *longissimus thoracis et lumborum* marbling by image analysis and relationships between meat quality parameters. *PLoS One*, 13(8), e0202535. <https://doi.org/10.1371/journal.pone.0202535>
- Girolami, A., Napolitano, F., Faraone, D., Braghieri, A. (2013). Measurement of meat color using a computer vision system. *Meat Science*, 93(1), 111–118. <https://doi.org/10.1016/j.meatsci.2012.08.010>
- Gonçalves, D.N., Moares Weber, V.A. de, Pistori, J.G.B., Costa Gomes, R. da, Araujo, A.V. de, Pereira, M.F., Gonçalves, W.N., Pistori, H. (2021) Carcass image segmentation using CNN-based methods. *Information Processing in Agriculture*, 8(4), 560-572. <https://doi.org/10.1016/j.inpa.2020.11.004>
- Google Inc. (n.d). TensorFlow Lite. <https://www.tensorflow.org/lite> (Accessed September 15, 2024).
- Goralski, M.A., Tan, T.K. (2022) Artificial intelligence and poverty alleviation: emerging innovations and their implications for management education and sustainable development. *International Journal of Management Education*, 20(3), 100662. <https://doi.org/10.1016/j.ijme.2022.100662>
- Gorji, H.T., Van Kessel, J.A.S., Haley, B.J., Husarik, K., Sonnier, J., Shahabi, S.M., Zadeh, H.K., Chan, D.E., Qin, J., Baek, I., Kim, M.S., Akhbardeh, A., Sohrabi, M., Kerge, B., MacKinnon, N., Vasefi, F., Tavakolian, K. (2022) Deep learning and multiwavelength fluorescence imaging for cleanliness assessment and disinfection in food services. *Frontiers in Sensors*, 3, 977770. <https://doi.org/10.3389/fsens.2022.977770>
- Grimes, L.M., Naganathan, G.K., Subbiah, J., Calkins, C.R. (2007). Hyperspectral imaging: a non-invasive technique to predict beef tenderness. In *Beef Cattle Report 2007* (pp. 97–99). University of Nebraska – Lincoln. MP90 <https://digitalcommons.unl.edu/cgi/viewcontent.cgi?article=1090&context=animalscinbcr>.
- Hinton, G. E., Osindero, S., and Teh, Y.-W. (2006). A fast learning algorithm for deep belief nets. *Neural Computation*, 18 (7), 1527–1554. <https://doi.org/10.1162/neco.2006.18.7.1527>
- How, M-L, Chan, Y.J., Cheah, S-M. (2020) Predictive insights for improving the resilience of Global Food Security using Artificial Intelligence. *Sustainability*, 12(15), 6272. <https://doi.org/10.3390/su12156272>
- Islam, S. M. M., Rahman, A., Prasad, N., Boric-Lubecke, O., and Lubecke, V. M. (2019). Identity authentication system using a support vector machine (SVM) on radar respiration measurements. *2019 93rd ARFTG Microwave Measurement Conference (ARFTG)*, Boston, MA, USA, 2019, pp. 1-5. <https://doi.org/10.1109/ARFTG.2019.8739240>
- Jackman, P., Sun, D.W., Allen, P. (2009b). Comparison of the predictive power of beef surface wavelet texture features at high and low magnification. *Meat Science*, 82, 353–356. <https://doi.org/10.1016/j.meatsci.2009.02.006>

- Jackman, P., Sun, D.W., Allen, P. (2009c). Comparison of various wavelet texture features to predict beef palatability. *Meat Science*, 83, 82–87. <https://doi.org/10.1016/j.meatsci.2009.04.003>
- Jackman, P., Sun, D.W., Allen, P. (2009d). Automatic segmentation of beef *longissimus dorsi* muscle and marbling by an adaptable algorithm. *Meat Science*, 83, 187–194. <https://doi.org/10.1016/j.meatsci.2009.03.010>
- Jackman, P., Sun, D.W., Du, C-J., Allen, P. (2009a). Prediction of beef eating qualities from colour, marbling and wavelet surface texture features using homogenous carcass treatment. *Pattern Recognition*, 42, 751–763. <https://doi.org/10.1016/j.patcog.2008.09.009>
- Jackman, P., Sun, D.W., Du, C-J., Allen, P., Downey, G. (2008). Prediction of beef eating quality from colour, marbling and wavelet texture features. *Meat Science*, 80, 1273–1281. <https://doi.org/10.1016/j.meatsci.2008.06.001>
- Jay, N.P., Van de Ven, R.J., Hopkins, D.L. (2014). Comparison of rankings for lean meat based on results from a CT scanner and a video image analysis system. *Meat Science*, 98, 316–320. <https://doi.org/10.1016/j.meatsci.2014.05.006>
- Jia, S., Ping, W., Peiyi, J., Hu, S. (2017). Research on data augmentation for image classification based on convolution neural networks. *2017 Chinese Automation Congress (CAC)*, 4165-4170. <https://doi.org/10.1109/CAC.2017.8243510>
- Jopson, N.B., Newman, S.A.N., McEwan, J.C. (2009). Developments in the sheep industry: genetic evaluation of meat yield. *Proceedings of the New Zealand Society of Animal Production*, 69, 161–164. [http://refhub.elsevier.com/S0309-1740\(22\)00172-3/rf0250](http://refhub.elsevier.com/S0309-1740(22)00172-3/rf0250)
- Jwade, S.A., Guzzomi, A., Mian, A. (2019). On farm automatic sheep breed classification using deep learning. *Computers and Electronics in Agriculture*, 167, 105055. <https://doi.org/10.1016/j.compag.2019.105055>
- Kamruzzaman, M., Makino, Y., Oshita, S. (2016). Parsimonious model development for real-time monitoring of moisture in red meat using hyperspectral imaging. *Food Chemistry*, 196, 1084–1091. <https://doi.org/10.1016/j.foodchem.2015.10.051>
- Kang, R., Yang, K., Xia Zhang, X., Wu, W., Jie Chen, K. (2016). Development of online detection and processing system for contaminants on chicken carcass surface. *Applied Engineering in Agriculture*, 32(1), 133–139. <https://doi.org/10.13031/aea.32.11200>
- Krizhevsky, A., Sutskever, I., and Hinton, G.E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1097–1105. https://proceedings.neurips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf
- Krizhevsky, A., Sutskever, I., and Hinton, G.E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>
- Kutyauripo, I., Rushambwa, M, Chiwazi, L. (2023) Artificial intelligence applications in the agrifood sectors. *Journal of Agriculture and Food Research*, 11, 100502. <https://doi.org/10.1016/j.jafr.2023.100502>

- Kvam, J., & Kongsro, J. (2017). In vivo prediction of intramuscular fat using ultrasound and deep learning. *Computers and Electronics in Agriculture*, 142, 521–523. <https://doi.org/10.1016/j.compag.2017.11.020>
- Lambe, N.R., Clelland, N., Draper, J., Smith, E.M., Yates, J., Bunger, L. (2021). Prediction of intramuscular fat in lamb by visible and near-infrared spectroscopy in an abattoir environment. *Meat Science*, 171, 108286. <https://doi.org/10.1016/j.meatsci.2020.108286>
- Li, J., Tan, J., Martz, F.A., Heymann, H. (1999). Image texture features as indicators of beef tenderness. *Meat Science*, 53, 17–22. [https://doi.org/10.1016/S0309-1740\(99\)00031-5](https://doi.org/10.1016/S0309-1740(99)00031-5)
- Li, J., Tan, J., Shatadal, P. (2001). Classification of tough and tender beef by image texture analysis. *Meat Science*, 57, 341–346. [https://doi.org/10.1016/S0309-1740\(00\)00105-4](https://doi.org/10.1016/S0309-1740(00)00105-4)
- Liu, J., Sun, X., Young, J., & Newman, D. (2018a). PSIX-21 computer vision system as a tool to predict intramuscular fat of pork whole loin and chop. *Journal of Animal Science*, 96(Suppl. 3), 280–281. <https://doi.org/10.1093/jas/sky404.616>
- Liu, J.-H., Sun, X., Young, J.M., Bachmeier, L. A., and Newman, D. J. (2018b). Predicting pork loin intramuscular fat using computer vision system. *Meat Science*, 143, 18–23. <https://doi.org/10.1016/j.meatsci.2018.03.020>
- Lopes, J.F., Barbon, A.P.A.C., Orlandi, G., Calvini, R., Lo Fiego, D.P., Ulrici, A., Barbon, S. (2020). Dual stage image analysis for a complex pattern classification task: ham veining defect detection. *Biosystems Engineering*, 191, 129–144. <https://doi.org/10.1016/j.biosystemseng.2020.01.008>
- López-Campos, Ó., Roberts, J.C., Larsen, I.L., Prieto, N., Juárez, M., Dugan, M.E.R., Aalhus, J.L. (2018). Rapid and non-destructive determination of lean fat and bone content in beef using dual energy X-ray absorptiometry. *Meat Science*, 146, 140–146. <https://doi.org/10.1016/j.meatsci.2018.07.009>
- Louro da Silva, M., Gouveia, C., Albuquerque, D.F., Plácido da Silva, H. (2024) Radar-based invisible biometric authentication. *Information*, 15(1), 44. <https://doi.org/10.3390/info15010044>
- Ma, J., & Sun, D.-W. (2020). Prediction of monounsaturated and polyunsaturated fatty acids of various processed pork meats using improved hyperspectral imaging technique. *Food Chemistry*, 321, 126695. <https://doi.org/10.1016/j.foodchem.2020.126695>
- Maes, D., Sibila, M., Pieters, M., Haesebrouck, F., Segalés, J., Oliveira, L.G. de (2023). Review on the methodology to assess respiratory tract lesions in pigs and their production impact. *Veterinary Research*, 54(1), 8. <https://doi.org/10.1186/s13567-023-01136-2>
- Mahadevkar, S., Patil, S., & Kotecha, K. (2024). Enhancement of handwritten text recognition using AI-based hybrid approach. *MethodsX*, 12, 102654. <https://doi.org/10.1016/j.mex.2024.102654>
- Manko, M., Smolkin, O., Romanov, D., Esper, I. de M., Popov, A., Sahumbaiev, I., Cordova-Lopez, L.E., Mason, A. (2024) Deep learning model for automatic limb

- detection and gripping in a novel meat factory cell. *Smart Agricultural Technology*, 8, 100486. <https://doi.org/10.1016/j.atech.2024.100486>
- Masferrer, G., Carreras, R., Font-i-Furnols, M., Gispert, M., Marti-Puig, P., Serra, M. (2018). On-line ham grading using pattern recognition models based on available data in commercial pig slaughterhouses. *Meat Science*, 143, 39–45. <https://doi.org/10.1016/j.meatsci.2018.04.011>
- Mason, A., Romanov, D., Cordova-Lopez, L.E., Ross, S., Korostynska, O. (2022). Smart knife: technological advances towards smart cutting tools in meat industry automation. *Sensor Review*, 42(1), 155–163. <https://doi.org/10.1108/SR-09-2021-0315>
- Matthews, D., Pabiou, T., Evans, R.D., Beder, C., Daly, A. (2022) Predicting carcass cut yields in cattle from digital images using artificial intelligence. *Meat Science*, 184, 108671. <https://doi.org/10.1016/j.meatsci.2021.108671>
- Medathati, N.V.K., Neumann, H., Masson, G.S., Kornprobst, P. (2016). Bio-inspired computer vision: towards a synergistic approach of artificial and biological vision. *Computer Vision and Image Understanding*, 150, 1–30. <https://doi.org/10.1016/j.cviu.2016.04.009>
- Meunier, B., Normand, J., Albouy-Kissi, B., Micol, D., El Jabri, M., Bonnet, M. (2020). An open-access computer image analysis (CIA) method to predict meat and fat content from an android smartphone-derived picture of the bovine 5th-6th rib. *Methods*, 186, 79–89. <https://doi.org/10.1016/j.ymeth.2020.06.023>
- Miyazawa, T., Hiratsuka, Y., Toda, M., Hatakeyama, N., Ozawa, H., Abe, C., Cheng, T. Y., Matsushima, Y., Miyawaki, Y., Ashida, K., Imura, J., Tsuda, T., Bushita, H., Tomonobu, K., Ohta, S., Chung, H., Omae, Y., Yamamoto, T., Morinaga, M., Ochi, H., Miyazawa, T. (2022). Artificial intelligence in food science and nutrition: a narrative review. *Nutrition Reviews*, 80(12), 2288–2300. <https://doi.org/10.1093/nutrit/nuac033>
- Modzelewska-Kapituła, M., & Cierach, M. (2012). Correlation of the attributes measured by computer vision with moisture and fat content of meat batters. *Food Science and Technology Research*, 6, 769–779. <https://doi.org/10.3136/fstr.18.769>
- Modzelewska-Kapituła, M., & Jun, S. (2022). The application of computer vision systems in meat science and industry – a review. *Meat Science*, 192, 108904. <https://doi.org/10.1016/j.meatsci.2022.108904>
- Modzelewska-Kapituła, M., & Wróblewski, P. (2014). Comparison of texture, cooking losses and degree of shrinkage of grilled steaks from bovine *longissimus dorsi* and *semitendinosus* muscles. *Nauka Przyroda Technologie*, 8(2), 20. https://www.npt.up-poznan.net/pub/art_8_20.pdf
- Monteschio, J.O., Vargas-Junior, F.M., Almeida, F.L.A., Pinto, L.A., Kaneko, I.N., Almeida, A.A., Prado, I.N. (2019). The effect of encapsulated active principles (eugenol, thymol and vanillin) and clove and rosemary essential oils on the structure, collagen content, chemical composition and fatty acid profile of Nellore heifers muscle. *Meat Science*, 155, 27–35. <https://doi.org/10.1016/j.meatsci.2019.04.019>

- Mora, N.H.A.P., Macedo, F.A.F., Mexia, A.A., Senegalhe, F.B.D., Almeida, F.L.A., Possamai, A.P.S., Araújo, G.G.L. (2015). Physicochemical characteristics of meat from pantaneiro lambs slaughtered with different of subcutaneous fat thicknesses. *Semina: Ciências Agrárias*, 36(4), 2819–2828. <https://doi.org/10.5433/1679-0359.2015V36N4P2819>
- Naganathan, G.K., Grimes, L.M., Subbiah, J., Calkins, C.R., Samal, A., Meyer, G.E. (2008). Visible/near-infrared hyperspectral imaging for beef tenderness prediction. *Computers and Electronics in Agriculture*, 64, 225–233. <https://doi.org/10.1016/j.compag.2008.05.020>
- Nakahashi, Y., Maruyama, S., Seki, S., Hidaka, S., Kuchida, K. (2008). Relationships between monounsaturated fatty acids of marbling flecks and image analysis traits in longissimus muscle for Japanese black steers. *Journal of Animal Science*, 86, 3551–3556. <https://doi.org/10.2527/jas.2008-0947>
- O’Sullivan, M.G., Byrne, D.V., Martens, H., Gidskehaug, L.H., Andersen, H.J., Martens, M. (2003). Evaluation of pork colour: prediction of visual sensory quality of meat from instrumental and computer vision methods of colour analysis. *Meat Science*, 65, 909–918. [https://doi.org/10.1016/S0309-1740\(02\)00298-X](https://doi.org/10.1016/S0309-1740(02)00298-X)
- OECD/FAO (2023), *OECD-FAO Agricultural Outlook 2023-2032*, OECD Publishing, Paris, <https://doi.org/10.1787/08801ab7-en>
- Olsen, A., Konovalov, D.A., Philippa, B., Ridd, P., Wood, J.C., Johns, J., et al. (2019). DeepWeeds: a multiclass weed species image dataset for deep learning. *Scientific Reports*, 9(1), 2058. <https://doi.org/10.1038/s41598-018-38343-3>
- Pabiou, T., Fikse, W.F., Cromie, A.R., Keane, M.G., Näsholm, A., Berry, D.P. (2011) Use of digital images to predict carcass cut yields in cattle. *Livestock Science*, 137(1–3), 130–140. <https://doi.org/10.1016/j.livsci.2010.10.012>
- Ranasinghesagara, J., Nath, T.M., Wells, S.J., Weaver, A.D., Gerrard, D.E., Yao, G. (2010). Imaging optical diffuse reflectance in beef muscles for tenderness prediction. *Meat Science*, 84, 413–421. <https://doi.org/10.1016/j.meatsci.2009.09.010>
- Redhu, N.S., Thakur, Z., Yashveer, S., Mor, P. (2022) Artificial intelligence: a way forward for agricultural sciences. *Bioinformatics in Agriculture: Next Generation Sequencing Era*, 37, 641–668. <https://doi.org/10.1016/B978-0-323-89778-5.00007-6>
- Ruedt, C., Gibis, M., Weiss, J. (2020). Quantification of surface iridescence in meat products by digital image analysis. *Meat Science*, 163, 108064. <https://doi.org/10.1016/j.meatsci.2020.108064>
- Scholz, A.M., Bünger, L., Kongsro, J., Baulain, U., Mitchell, A.D. (2015). Non-invasive methods for the determination of body and carcass composition in livestock: dual energy X-ray absorptiometry, computed tomography, magnetic resonance imaging and ultrasound: invited review. *Animal*, 9(7), 1250–1264. <https://doi.org/10.1017/S1751731115000336>
- Segura, J., Aalhus, J.L., Prieto, N., Larsen, I.L., Juárez, M., López-Campos, Ó. (2021). Carcass and primal composition predictions using camera vision systems

- (CVS) and dual-energy X-ray absorptiometry (DXA) technologies on mature cows. *Foods*, 10(5), 1118. <https://doi.org/10.3390/foods10051118>
- Segura, J., Aalhus, J.L., Prieto, N., Zawadski, S., Scott, H., López-Campos, Ó. (2023). Prediction of primal and retail cut weights, tissue composition and yields of youthful cattle carcasses using computer vision systems; whole carcass camera and/or ribeye camera. *Meat Science*, 199, 109120. <https://doi.org/10.1016/j.meatsci.2023.109120>
- Shahinfar, S., Kelman, K., Kahn, L. (2019) Prediction of sheep carcass traits from early-life records using machine learning. *Computers and Electronics in Agriculture*, 156, 159-177. <https://doi.org/10.1016/j.compag.2018.11.021>
- Shi, Y., Wang, X., Borhan, M. S., Young, J., Newman, D., Berg, E., Sun, X. (2021). A review on meat quality evaluation methods based on non-destructive computer vision and artificial intelligence technologies. *Food Science of Animal Resources*, 41(4), 563–588. <https://doi.org/10.5851/kosfa.2021.e25>
- Sifre-Maunier, L., Taylor, R.G., Berge, P., Culioli, J., Bonny, J.M. (2006). A global unimodal thresholding based on probabilistic reference maps for the segmentation of muscle images. *Image and Vision Computing*, 24, 1080–1089. <https://doi.org/10.1016/j.imavis.2006.03.004>
- Simonyan, K. & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *Computer Vision and Pattern Recognition*. <https://doi.org/10.48550/arXiv.1409.1556>
- Stewart, S.M., Gardner, G.E., Williams, A., Pethick, D.W., McGilchrist, P., Kuchida, K. (2021a). Association between visual marbling score and chemical intramuscular fat with camera marbling percentage in Australian beef carcasses. *Meat Science*, 181, 108369. <https://doi.org/10.1016/j.meatsci.2020.108369>
- Stewart, S.M., Lauridsen, T., Toft, H., Pethick, D.W., Gardner, G.E., McGilchrist, P., Christensen, M. (2021b). Objective grading of eye muscle area, intramuscular fat and marbling in Australian beef and lamb. *Meat Science*, 181, 108358. <https://doi.org/10.1016/j.meatsci.2020.108358>
- Sun, X., Chen, K. J., Maddock-Carlin, K. R., Anderson, V. L., Lepper, A. N., Schwartz, C. A., et al. (2012). Predicting beef tenderness using color and multispectral image texture features. *Meat Science*, 92 (4), 386–393. <https://doi.org/10.1016/j.meatsci.2012.04.030>
- Sun, X., Young, J., Liu, J.-H., and Newman, D. (2018). Prediction of Pork Loin Quality Using Online Computer Vision System and Artificial Intelligence Model. *Meat Science*, 140, 72–77. <https://doi.org/10.1016/j.meatsci.2018.03.005>
- Sunil, G. C., Saidul Md, B., Zhang, Y., Reed, D., Ahsan, M., Berg, E., Sun, X. (2021) Using deep learning neural network in artificial intelligence technology to classify beef cuts. *Frontiers in Sensors*, 2, 654357. <https://doi.org/10.3389/fsens.2021.654357>
- Szegedy, C., Ioffe, S., Vanhoucke, V., Alemi, A. (2016). Inception-v4, Inception-ResNet and the impact of residual connections on learning. *Computer Vision and Pattern Recognition*. <https://doi.org/10.48550/arXiv.1602.07261>
- TensorFlow (n.d.). <https://www.tensorflow.org/> (Accessed September 15, 2024).

- Todhunter, M.E., Jubair, S., Verma, R., Saje, R., Shen, K., Duffy, B. (2024) Artificial intelligence and machine learning applications for cultured meat. *Computers and Society*. <https://doi.org/10.48550/arXiv.2407.09982>
- Tomasevic, I., Tomovic, V., Milovanovic, B., Lorenzo, J., Dorđević, V., Karabasil, N., Djekic, I. (2019). Comparison of a computer vision system vs. traditional colorimeter for color evaluation of meat products with various physical properties. *Meat Science*, 148, 5–12. <https://doi.org/10.1016/j.meatsci.2018.09.015>
- Too, E.C., Yujian, L., Njuki, S., and Yingchun, L. (2019). A comparative study of fine-tuning deep learning models for plant disease identification. *Computers and Electronics in Agriculture*, 161, 272–279. <https://doi.org/10.1016/j.compag.2018.03.032>
- Uttaro, B., & Aalhus, J.L. (2007). Effect of thawing rate on distribution of an injected salt and phosphate brine in beef. *Meat Science*, 75, 480–486. <https://doi.org/10.1016/j.meatsci.2006.08.015>
- Wakholi, C., Kim, J., Nabwire, S., Kwon, K-D., Mo, C., Cho, S., Cho, B-K. (2022) Deep learning feature extraction for image-based beef carcass yield estimation. *Biosystems Engineering*, 218, 78-93. <https://doi.org/10.1016/j.biosystemseng.2022.04.008>
- Wang, M. & Li, X. (2024) Application of artificial intelligence techniques in meat processing: a review. *Journal of Food Process Engineering*, 47(3), e14590. <https://doi.org/10.1111/jfpe.14590>
- Wu, W., Chen, G.Y., Wu, M.Q., Yu, Z.W., Chen, K.J. (2017). Detection of diluted contaminants on chicken carcasses using a two-dimensional scatter plot based on a two-dimensional hyperspectral correlation spectrum. *Applied Optics*, 56(9), 72–78. <https://doi.org/10.1364/ao.56.000d72>
- Xiberta, P., Bardera, A., Boada, I., Gispert, M., Brun, A., Font-i-Furnols, M. (2018). Evaluation of an automatic lean meat percentage quantification method based on a partial volume model from computed tomography scans. *Computers and Electronics in Agriculture*, 151, 365–375. <https://doi.org/10.1016/j.compag.2018.06.019>
- Yang, C-C., Chao, K., Chen, Y-R. (2005). Development of multispectral image processing algorithms for identification of wholesome, septicemic, and inflammatory process chickens. *Journal of Food Engineering*, 69(2), 225–234. <https://doi.org/10.1016/j.jfoodeng.2004.07.021>
- Yang, C-C., Chao, K., Kim, M.S. (2009). Machine vision system for online inspection of freshly slaughtered chickens. *Sensing and Instrumentation for Food Quality and Safety*, 3(1), 70–80. <https://doi.org/10.1007/s11694-008-9067-8>
- Yi, Y., Ke, Z., Yi, C. An implementation of intelligent monitoring system for food processing. *2010 8th World Congress on Intelligent Control and Automation*, Jinan, China, 2010, 4225–4230. <https://doi.org/10.1109/WCICA.2010.5553845>
- You, S.D., Liu, CH., Chen, WK. (2018) Comparative study of singing voice detection based on deep neural networks and ensemble learning. *Human-centric Computing and Information Sciences*, 8, 34. <https://doi.org/10.1186/s13673-018-0158-1>

Yuan, R., Liu, G., He, J., Ma, C., Cheng, J., Fan, N., Ban, J., Li, Y., Sun, Y. (2020). Determination of metmyoglobin in cooked tan mutton using Vis/NIR hyperspectral imaging system. *Journal of Food Science*, 85, 1403–1410. <https://doi.org/10.1111/1750-3841.15137>

Zawacki-Richter, O., Marín, V.I., Bond, M., Gouverneur, F. (2019) Systematic review of research on artificial intelligence applications in higher education – where are the educators? *International Journal of Educational Technology in Higher Education*, 16, 39. <https://doi.org/10.1186/s41239-019-0171-0>

Zheng, C., Sun, D.W., Du, C.J. (2006). Estimating shrinkage of large cooked beef joints during air-blast cooling by computer vision. *Journal of Food Engineering*, 72, 56–62. <https://doi.org/10.1016/j.jfoodeng.2004.11.018>

Zheng, C., Sun, D.W., Zheng, L. (2007). A new region-primitive method for classification of colour meat image texture based on size, orientation, and contrast. *Meat Science*, 76, 620–627. <https://doi.org/10.1016/j.meatsci.2007.02.003>

CAPÍTULO III

TAMANHO AMOSTRAL EM EXPERIMENTAÇÃO ZOOTÉCNICA

Paulo Santana Pacheco³

³ Universidade Federal de Santa Maria (UFSM), Santa Maria/RS, Brasil. E-mail: paulo.pacheco@ufsm.br

1 INTRODUÇÃO

Desde muito tempo a Zootecnia tem como ramo de atuação a pesquisa e/ou experimentação aplicada às diversas espécies animais de interesse econômico.

Conforme levantamento divulgado pela Associação Brasileira de Zootecnistas (2019), comparativamente aos demais países que tradicionalmente investem em pesquisa/experimentação com animais de produção, é de se aplaudir a posição em que o Brasil ocupa em relação ao número de publicações científicas em periódicos indexados (Figura 1), tendo em vista os diversos desafios que os pesquisadores enfrentam.






Country	↓ Documents	Citable documents	Citations	Self-Citations	Citations per Document	H index
1  United States	110595	107168	1950833	925757	17.64	250
2  Brazil	40381	39324	292785	192713	7.25	91
3  United Kingdom	34621	32815	683259	182518	19.74	196
4  Germany	27147	26512	385753	110320	14.21	145
5  Canada	24130	23614	454778	120653	18.85	160

Figura 1 – Ranking parcial da lista de países que mais produzem artigos científicos na área da Zootecnia (levantamento de 1996 a 2017). Fonte: ABZ (2019).

Ocorre que as publicações científicas tem como parte integrante a descrição da metodologia e dos métodos de condução do ensaio, incluindo a metodologia estatística.

Este aspecto é muito interessante, pois embora o profissional zootecnista atue atendendo as mais diversas necessidades envolvendo a produção de alimentos de origem animal, precisa de alguns conhecimentos da área das ciências exatas, no caso da Estatística, para atender aos requisitos necessários para atingir o que poderíamos dizer de experimento/pesquisa de qualidade.

O que seria pesquisa/experimento de qualidade? Seria atender uma série de exigências metodológicas para que a conclusão do ensaio seja confiável. Por exemplo: Definir o método de amostragem, qual a unidade experimental, o nível de

significância, o delineamento experimental, a análise estatística, entre outros, inclusive o tema deste artigo: o tamanho amostral.

A estatística experimental teve seu marco de fundação no início do século 20, anterior ao uso do computador, e podemos dizer que este conhecimento revolucionou a ciência em geral. Depois, com a popularização dos computadores e softwares específicos para análise estatística de dados, a realização e publicação de resultados de ensaios científicos só vem aumentando.

Por exemplo, no caso da Zootecnia, podemos afirmar que a cada ano, mais de 3 mil novos estudos na forma de resumos são apresentados em congressos científicos no Brasil. Se considerarmos as publicações em periódicos científicos indexados no mundo todo, temos então uma montanha de informações à disposição para consulta e atualização por um profissional da área.

Será que toda esta informação é merecedora de atenção? Será que podemos confiar (sem questionar) em todas as conclusões de todas estas publicações na área zootécnica? Ao levarmos em consideração os aspectos teóricos/metodológicos envolvendo a parte da Estatística, temos profissionais como RICHARDSON et al. (2004) e VAZ (2016) que se dedicaram a responder estes questionamentos e suas considerações lançam um alerta aos aspirantes a pesquisadores (as).

Falhas metodológicas em aspectos básicos da pesquisa/experimentação científica, como por exemplo o tamanho amostral, ainda precisam ser corrigidos e/ou melhor esclarecidos.

Afinal, porque o tamanho amostral ainda é um tema tão importante na pesquisa/experimentação zootécnica nos dias atuais? Eis os motivos: Redução de custos; maximização de tempo, de esforço e de uso de outros recursos; considerações éticas e de bem estar dos animais; e confiabilidade na conclusão do ensaio.

A abordagem deste tema não irá tomar o rumo da teoria pura, e sim apresentar sua relevância, com aplicação prática e exemplificada com uso de software, visando esclarecer e treinar os interessados em atender um dos requisitos de elaboração e execução de um ensaio experimental, bem como interpretação da qualidade de dados já publicados.

2 MÉTODOS SIMPLES DE DETERMINAÇÃO DO TAMANHO AMOSTRAL

Inicialmente apresentam-se algumas maneiras mais simples de se determinar o tamanho amostral.

Vejamos o que consta no livro de GOMES (1990), um dos mais divulgados (senão o mais) na área de experimentação vegetal e animal no Brasil. O autor sugere no mínimo tamanho amostral de 20 e/ou pelo menos 10 graus de liberdade para o erro. Vale o comentário que o mesmo autor também cita outras maneiras mais precisas de cálculo do tamanho amostral.

No caso de um ensaio com o objetivo de se **comparar grupos** (análise de variância - ANOVA). ARIFIN e ZAHIRUDDIN (2017) propõem as seguintes equações para cálculo do número de repetições (r) por tratamento (t):

$$r \text{ mínimo} = (10 / t) + 1;$$

$$r \text{ máximo} = (20 / t) + 1.$$

Assim, multiplicando-se o valor mínimo ou o valor máximo obtido pelo número de tratamentos, obtêm-se o tamanho da amostra.

No caso de análise de **regressão**, GREEN (1991) apresenta a seguinte regra, utilizando o valor do r^2 (coeficiente de determinação do modelo) para determinação do tamanho da amostra:

$$n = 50 + 8 k, \text{ onde } k = n^\circ \text{ de preditores.}$$

No entanto, FIELD e MILES (2010) comenta sobre algo que será melhor esclarecido no desenvolver deste texto: a importância do tamanho do efeito e do poder do teste na definição do tamanho da amostra. O primeiro define o quão bem as variáveis independentes predizem as dependentes e o segundo a confiabilidade com a qual queremos detectar esses efeitos.

3 TAMANHO DA AMOSTRA E SUA RELAÇÃO COM O PODER DO TESTE

Com a estatística inferencial podemos fazer a estimação de parâmetros populacionais e também testes de hipóteses. Isto porque ao realizar uma pesquisa, o pesquisador busca comprovar alguma hipótese que estabeleceu.

Dois **tipos de hipóteses** são formulados, de acordo com ALVES (2021):

Hipótese nula (H_0) – indica que não há diferenças entre tratamentos (Quali) ou não há relação entre variáveis (Quanti) e;

Hipótese alternativa (H_1) – indica que há diferenças entre tratamentos ou há relação entre variáveis. Pode ser do tipo bilateral (diferente) ou tipo unilateral (maior que ou menor que).

Assim, a decisão final do teste de hipóteses sempre consiste em rejeitar ou não rejeitar H_0 (Se rejeitar H_0 , significa que aceita H_1 como verdadeira e vice-versa). Mas para isso, devemos considerar o nível de significância (α – alpha) e o valor P obtido na análise estatística.

O **Nível de significância (α – alpha)** é um valor de corte (também é comum utilizar o termo: ‘efeito significativo’ ou ‘efeito estatisticamente significativo’ quando se rejeita H_0), utilizado para rejeitar H_0 ou não. Em Zootecnia, geralmente o valor de α (alpha) = 0,05 ou 5%, no entanto, pode ser modificado de acordo com o tipo de trabalho que se executa, com os riscos envolvidos na aplicação dos resultados ou por outros motivos. O pesquisador é quem define o valor de α , no entanto, sugere-se que isto seja feito *a priori* da execução da pesquisa. Por convenção, assume-se que um teste é significativo quando a probabilidade a ele associada é menor ou igual a 5%, ou seja, comparamos o *nível de significância* com o *valor P* de um teste inferencial de hipóteses para tomar esta decisão.

Existem vários testes de hipóteses em Estatística inferencial, e o conhecimento prévio da base teórica de experimentação auxilia o pesquisador na tomada de decisão sobre qual teste estatístico deve utilizar. Ex.: Quando os tratamentos são de natureza ‘Qualitativa’, aplicamos análises como *teste t* e *ANOVA*. Quando os tratamentos são de natureza ‘Quantitativa’, utilizamos análises de *correlação de Pearson* e *regressão linear*.

O **Valor de P** é uma probabilidade (varia de 0 a 100% ou 0,00 a 1,00) que representa a diferença entre os tratamentos ter ocorrido ao acaso (ou a probabilidade de a relação verificada entre as variáveis ter ocorrido ao acaso), ou seja, apenas amostral.

Exemplificando, se o valor de $P \leq 0,05$ (ou 5%) indica que há uma ‘pequena probabilidade’ (menor ou igual que 5%) de que a diferença observada entre as médias dos tratamentos (ou relação entre variáveis) seja ao acaso. Então afirmamos que há diferença estatisticamente significativa, pois rejeitamos H_0 . E se o valor P de um teste de hipóteses inferencial obtido for 8,0% ($P = 0,080$), o que significa? Significa que é maior que 5% (0,05), aceitamos H_0 (rejeitamos H_1), não há diferença estatisticamente significativa entre tratamentos (ou relação entre variáveis), pois foi ao acaso (e não um efeito dos tratamentos).

Na aplicação de um teste estatístico de hipóteses qualquer, associam-se dois tipos de erros: Erro tipo I e Erro tipo II, que fazem parte do processo de decisão entre aceitar H_0 ou aceitar H_1 .

O **Erro tipo I** ocorre quando se rejeita H_0 que é verdadeira, ou seja, quando afirmamos que há diferença entre tratamentos (ou relação entre variáveis) quando na verdade esta diferença não existe.

O **Erro tipo II** (ou β - beta) é o oposto, ocorre quando se aceita H_0 quando é falsa, ou seja, quando afirmamos que não há diferença entre tratamentos (ou relação entre variáveis) quando na verdade esta diferença existe.

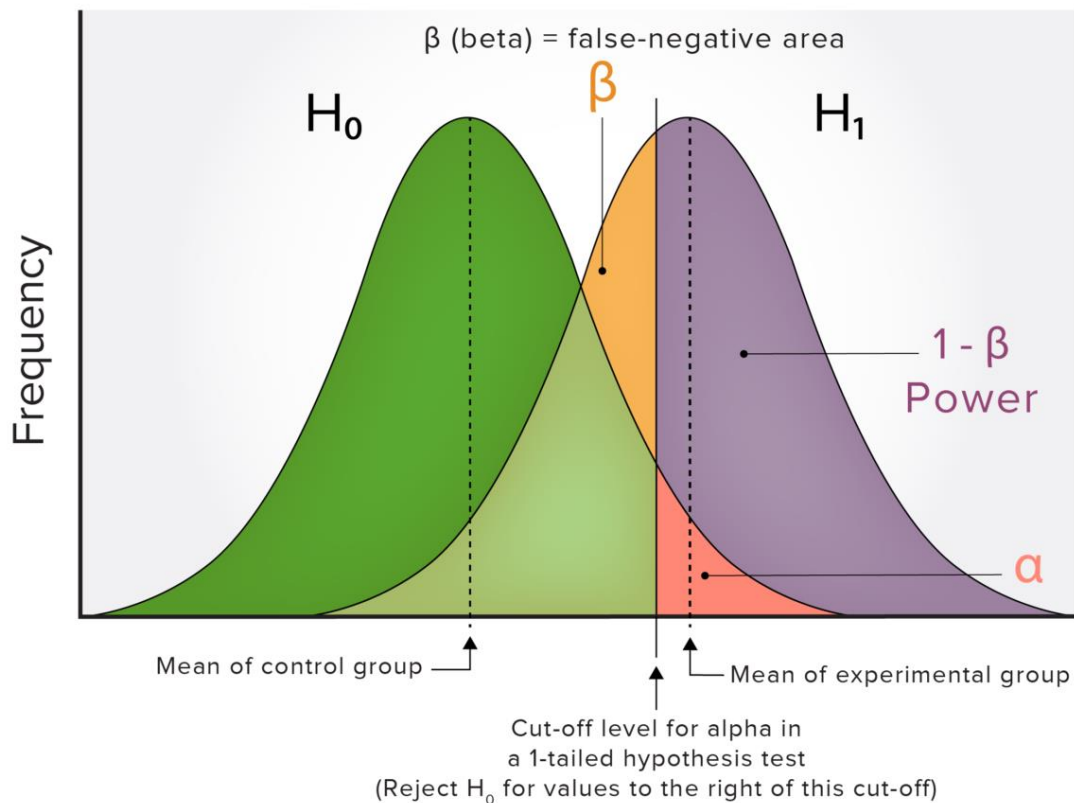
Estas possibilidades são apresentadas na Tabela 1, que representa a matriz de confusão.

Tabela 1 – Tipos de erros na tomada de decisões (matriz de confusão).

Hipótese (realidade)	Decisão do teste de hipóteses	
	Aceitar H_0	Rejeitar H_0
H_0	Correta Prob = $1 - \alpha$	Erro tipo I Prob = α (nível de significância)
H_1	Erro tipo II Prob = β	Correta Prob = $1 - \beta$ (poder do teste)

Beta (β) é a probabilidade de cometermos o Erro tipo II: aceitar H_0 quando H_1 é verdadeira. Então $1 - \beta$ ou **Poder do teste** (Figura 2, obtida de OISETH et al., 2022), é a probabilidade de se tomar a decisão correta: aceitar H_1 quando é

verdadeira, a confiabilidade em afirmar que existe diferença entre tratamentos (ou relação entre variáveis) quando isto é verdadeiro.



Alfa (α) = P(rejeitar H_0 | H_0 seja verdadeira) ou P(**Erro tipo I**).
 Beta (β) = P(Aceitar H_0 | H_1 seja verdadeira) ou P(**Erro tipo II**).
 Poder do teste = P(Rejeitar H_0 | H_1 seja verdadeira) ou **1 - Beta**.

Figura 2 – Representação da curva Normal de dois conjuntos de dados

Considera-se que o valor mínimo ideal do Poder de teste deve ser de 0,80 ou 80%. No entanto, é pouco (quase raro!) utilizado na pesquisa zootécnica. Representa uma sugestão, o pesquisador tem a liberdade de definir. Ex.: 0,90 ou 90%; 0,99 ou 99%. Também podemos entender o Poder do teste como a probabilidade de detectar uma diferença quando de fato ela existe.

É definido basicamente por: tamanho do efeito, tamanho da amostra, desvio padrão, nível de significância e teste estatístico a ser utilizado. Quanto maior o Tamanho do efeito, maior o Poder do teste; quanto menor o desvio padrão, maior o Poder do teste; quanto maior o nível de significância, maior o Poder do teste; quanto maior o tamanho da amostra, maior o Poder do teste.

3.1 Por que calcular o Poder do teste?

Quanto maior o Poder do teste, melhor, pois é mais provável que consigamos detectar um efeito – mas, mantendo um nível de significância (α) constante, só conseguimos aumentá-lo, à medida que aumentamos o tamanho amostral (n). O tamanho da amostra tem relação direta com o poder do teste. Assim, para maior confiabilidade nas conclusões de um estudo/experimento, deve-se estimar o n considerando o Poder do teste mínimo de 0,80 ou 80%.

Então, quanto maior o n , melhor, mas como as pesquisas zootécnicas trabalham com várias outras limitações, precisamos decidir o seguinte: Qual o tamanho de amostra mínimo ideal para que se tenha confiabilidade em afirmar que uma possível diferença verificada entre tratamentos (ou relação entre variáveis) seja realmente verdadeira? Ao definir o tamanho da amostra baseado no Poder do teste, não significa que iremos aceitar H_1 . Mas se aceitarmos H_1 , saberemos a confiabilidade desta decisão, que é o valor do Poder do teste.

3.2 Estimativas de Poder do teste em estudos zootécnicos

Para estimativa, pode-se fazer uso de dados de estudos/pesquisas já conduzidas e publicadas, realizarmos um ensaio piloto, ou calcularmos a partir do ensaio em questão.

Como será que está a confiabilidade das conclusões de pesquisas em Zootecnia no Brasil? Obviamente não se pode generalizar, no entanto, para se ter uma ideia, na Tabela 1 constam os resultados de estatísticas descritivas do Poder do teste calculadas a partir de resultados de pesquisas conduzidas na área de produção de bovinos de corte, envolvendo variáveis de desempenho, de comportamento ingestivo, de carcaça e de corpo vazio. Verifica-se que a média/mediana estão muito aquém do mínimo sugerido de 0,80 ou 80%. Agora que já se sabe o que significa este resultado, deixo as conclusões como tarefa de casa.

Tabela 1 – Estatísticas descritivas do Poder do teste calculadas para variáveis de desempenho em bovinos de corte ($r = n^\circ$ de repetições (média) obtido na literatura revisada; $n = n^\circ$ de observações utilizados para estimativa do Poder do teste; $r_{\text{mínimo}} = n^\circ$ repetições ideal mínimo sugerido para obter Poder de 0,80)

Grupo de variáveis	Com base na literatura revisada				$r_{\text{mínimo}}$ para Poder de 80%
	r	Poder do teste			
		Média	Mediana	n	
Ganho de peso	13	0,44	0,25	41	7 (-46%)*
Consumo	5	0,51	0,40	251	8 (+60%)
Conversão alimentar	5	0,42	0,26	43	7 (+40%)
Comportamento ingestivo	6	0,41	0,24	69	10 (+67%)
Métricas da carcaça	6	0,44	0,26	174	9 (+50%)
Componentes corpo vazio, %	6	0,42	0,23	233	9 (+50%)

* aumento ou redução no $r_{\text{mínimo}}$ comparado com r verificado na literatura.

Foram utilizados dados de 7 teses de doutorado e 47 dissertações de mestrado em período de 21 anos (entre 1991 e 2012) (adaptado de VAZ, 2016).

4 TAMANHO DA AMOSTRA E SUAS RELAÇÕES COM O TAMANHO DO EFEITO E P-VALOR

Tamanho do efeito é uma medida descritiva que serve como complemento ao teste de significância. Ele representa a magnitude – a força – do efeito experimental. Também pode ser definido como um conceito estatístico que mede a força da relação entre duas variáveis em escala numérica. Embora cada teste inferencial possa apresentar medidas de tamanho de efeito diferentes, o fundamento é o mesmo: medida que descreve a magnitude de um efeito – como ‘diferença entre tratamentos’ ou ‘relação entre variáveis’.

Em testes de hipóteses, o tamanho do efeito, o poder do teste, o tamanho da amostra e o nível de significância estão relacionados entre si.

Exemplificando, se compararmos o peso médio (kg) de borregos aos 6 meses de idade de três raças diferentes (Suffolk vs Texel vs Corriedale) (Figura 3), podemos verificar que quanto maior o tamanho do efeito, maior a diferença entre raças, mais fácil sua detecção, menor tamanho amostral requerido e maior poder do teste. Mas devemos lembrar que o tamanho de efeito não é necessariamente maior quando o valor P é menor e vice-versa.

O tamanho de efeito é, portanto, uma medida que sempre deve ser apresentada junto com o valor da significância estatística. Isso porque,

erroneamente, os autores acreditam que a informação mais importante sobre uma análise é se ela é ou não é significativa (baseado no valor de P). Mais que isso, vários autores acham que a significância do P ($P < 0,05$ ou $P < 0,0001$) é o que determina se um achado é forte ou não.

4.1 Por que calcular o tamanho do efeito?

Valor P não revela o tamanho (magnitude) do efeito - relata apenas, se o efeito existe. O valor P, quando comparado ao nível de significância (α), nos permite inferir se a diferença ou a relação testada é estatisticamente significativa. No entanto, não nos permite inferir sobre a magnitude ou quão forte é essa diferença ou relação.

Conforme SERDAR et al. (2021), o tamanho do efeito fornece informações importantes sobre o quão bem a variável ou variáveis independentes predizem a variável dependente. Tamanho de efeito baixo significa que as variáveis independentes não preveem bem porque estão apenas ligeiramente relacionadas à variável dependente. Por outro lado, tamanho de efeito elevado significa que as variáveis independentes são preditores muito bons da variável dependente, permitindo assim avaliar a eficiência de se prever os resultados das variáveis independentes.

Desta maneira, sugere-se a inclusão da significância estatística e do tamanho do efeito nos resultados de publicações científicas, permitindo maior abrangência na avaliação dos resultados verificados no ensaio. No entanto, esta sugestão ainda é pouco levada em consideração na pesquisa/experimentação zootécnica.

4.2 Como interpretar o valor do tamanho do efeito?

Não existe regra para classificar o tamanho do efeito, pois cada linha de pesquisa e cada área da ciência tem suas particularidades. No entanto, para fins didáticos, a Tabela 2 apresenta uma interpretação (apenas sugestão!) de alguns intervalos de valores.

Em Zootecnia é muito recente (talvez raro!) o uso do tamanho do efeito em publicações científicas. No entanto, a sugestão de classificação e interpretação de valores conforme a Tabela 2 parece apropriada. Deve-se atentar também para o fato de que valores muito elevados de tamanho de efeito geram tamanhos de amostra muito pequenos, podendo comprometer sua estimativa.

Tabela 2 – Interpretação sugerida de algumas medidas de tamanho de efeito.

w	r ²	f	d	r	η ²	Cohen (1988) e Serdar et al. (2021)
			< 0	< 0	-	Efeito inverso
		0,00	0,00	0,00	0,000	Sem efeito
		0,10	0,10	0,05	0,003	Sem efeito
0,10	0,04	0,10	0,20	0,10	0,010	Efeito pequeno
			0,30	0,15	0,022	
			0,40	0,20	0,039	
0,30	0,25	0,25	0,50	0,24	0,060	Efeito intermediário
			0,60	0,29	0,083	
			0,70	0,33	0,110	
0,50	0,64	0,40	0,80	0,37	0,140	Efeito grande
			0,90	0,41	0,168	
			≥ 1,0	0,45	0,200	

(f) f de Cohen; (d) d de Cohen; (r) coeficiente de correlação; (η²) eta quadrado ou r-square r².

4.3 Como apresentar um resultado de tamanho de efeito?

Tomando como exemplo a Figura 3, temos: em média, os borregos da raça Suffolk foram significativamente (P = 0,04) mais pesados do que os da raça Corriedale, com tamanho de efeito grande (d = 1,5). A diferença entre os pesos médios das raças Suffolk e Texel foi estatisticamente significativa (P = 0,0001), no entanto com tamanho de efeito pequeno.



MAIOR tamanho de efeito: SUFFOLK vs CORRIEDALE (Valor P = 0,04; d = 1,5)

MENOR tamanho de efeito: TEXEL vs CORRIEDALE (Valor P = 0,0001; d = 0,3)

Figura 3 – Comparação do peso médio em diferentes raças ovinas, ilustrando a magnitude do tamanho do efeito (MAIOR ou MENOR).

5 UTILIZANDO RECURSOS COMPUTACIONAIS

Temos uma vantagem atualmente para estimativa do tamanho da amostra necessária para atender a necessidade de pesquisas/experimentos de qualidade: são os recursos computacionais. A vantagem é a de que os profissionais pesquisadores (as) de áreas diferentes da estatística ganham tempo e também obtêm resultados precisos.

A maioria dos softwares atualmente apresentam interface amigável e intuitiva, no entanto, o mínimo de conhecimento teórico é necessário para fornecer as informações necessárias para realizar a análise, bem como interpretar os resultados.

Tomando-se como exemplo o uso do software SAS® Studio ou SAS® on Demand for Academics (<https://welcome.oda.sas.com>), que é livre para uso, com poucos cliques obtém-se o resultado tão almejado. Existem outros softwares de uso frequente, no entanto, em Zootecnia este é um dos mais utilizados para análises estatísticas, conforme CABRAL (2021).

São necessárias algumas informações estatísticas que podem variar de acordo com o tipo de análise. A título de exemplo, utilizaremos as seguintes:

- Tipo de análise estatística;
- Fatores de estudo / tratamentos;
- As médias dos tratamentos para uma variável dependente;
- Desvio padrão da variável dependente;
- Nível de significância;
- Poder do teste desejado;
- Número de repetições.

No menu à esquerda *Tasks and Utilities > Tasks > Power and Sample Size* existe pelo menos uma dúzia de opções para definição do tamanho amostral levando em consideração o tipo de análise estatística (Figura 4).

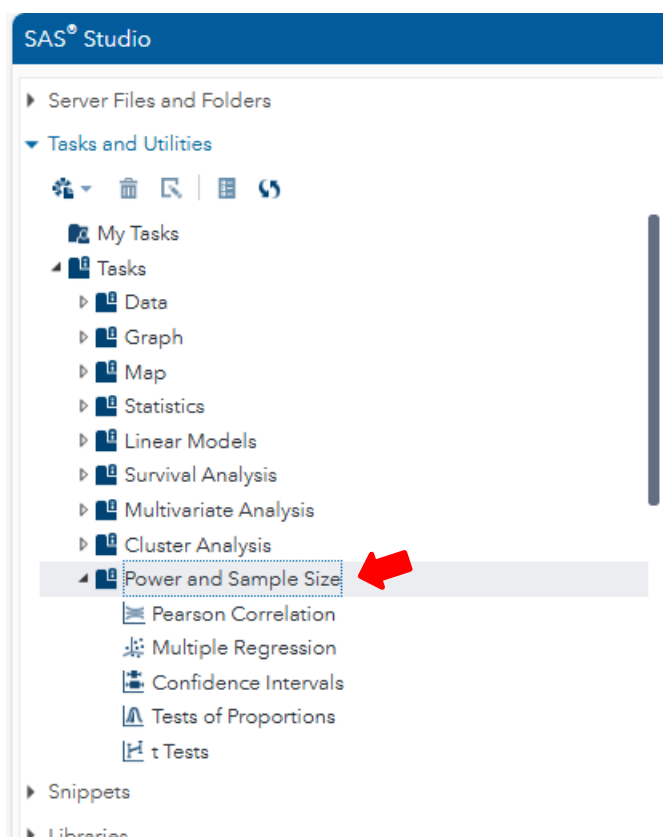


Figura 4 – Menu de opções *Power and Sample Size* do software SAS® Studio

Considerando que o Delineamento Inteiramente Casualizado é um dos mais utilizados na pesquisa/experimentação zootécnica (LÚCIO et al., 2003; FRANÇA, 2023), utilizaremos a opção *One-way ANOVA* e a partir da nova aba criada, preenche-se as opções pertinentes, conforme a Figura 5.

Na aba *Properties*, tem-se identificados por números as caixas de seleção passíveis de serem preenchidas, a saber:

- 1 – SOLVER FOR: há opção de escolher o tipo de saída/resultado da análise. No caso, foi marcado Power ou Poder do teste;
- 2 – NUMBER OF GROUPS: define-se o número de tratamentos. No exemplo, utilizaremos 3 tratamentos;
- 3 – SIGNIFICANCE LEVEL: define-se o nível de significância. No exemplo, 0,05 ou 5% é o padrão em Zootecnia;
- 4 – MEANS: informam-se as médias dos tratamentos para uma variável dependente qualquer. No exemplo, 0,32; 0,40 e 0,21 representam Ganho de peso em kg de cordeiros confinados por 85 dias;

5 – STANDARD DEVIATION: informa-se o desvio padrão da variável dependente em questão. No exemplo foi de 0,26 kg;

6 – SAMPLE SIZE: refere-se ao tamanho da amostra, onde foi marcada a opção *sample size per group* (nº repetições por tratamento) e após, informado o valor. No caso, constante para todos os tratamentos no valor e 5.

The screenshot displays the 'Properties' tab of the SAS Studio interface for a One-way ANOVA. The settings are as follows:

- SOLVE FOR:** Power (selected)
- NUMBER OF GROUPS:** 3
- SIGNIFICANCE LEVEL:** Alpha values: 0,05
- MEANS:** Group 1: 0,32; Group 2: 0,4; Group 3: 0,21
- STANDARD DEVIATION:** Standard deviation values: 0,26
- SAMPLE SIZE:** Allow fractional sample sizes: ; Select a form: Sample size per group; Sample sizes per group: 5

Figura 5 – Aba *Properties* do menu *Power and Sample Size > One-way ANOVA* do software SAS® Studio e suas caixas de seleção e/ou preenchimento

A próxima aba passível de preenchimento é a *Plots* (Figura 6), onde pode-se preencher o número mínimo e máximo de repetições por tratamento para gerar um gráfico de plotagem relacionado o Poder do teste com o número de repetições por tratamento. No exemplo, foi preenchido o mínimo de 2 e máximo de 100.

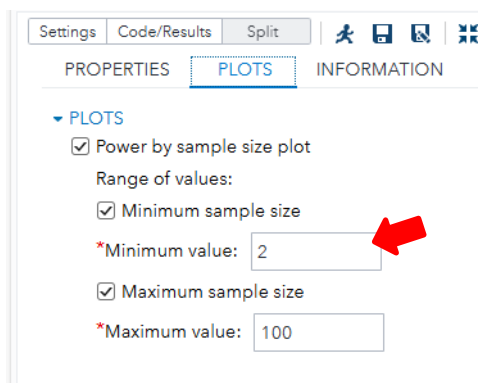


Figura 6 – Aba *Plots* do menu *Power and Sample Size > One-way ANOVA* do software SAS® Studio e suas caixas de seleção e/ou preenchimento

Após cumprir todas as etapas descritas anteriormente, clica-se em F3 e avaliam-se os resultados, conforme consta na Figura 7.

Na aba *Results* consta o Poder do teste estimado de 0,138 ou 13,8%. Este resultado está muito aquém do mínimo recomendado de 0,80 ou 80%, sugerindo que se deveria aumentar o tamanho amostral. Mas qual deveria ser então o tamanho amostral mínimo para atingir esta recomendação? Conforme o gráfico de plotagem, seria atingido com 37 repetições por tratamento x 3 tratamentos = 111 de tamanho amostral.

Pode acontecer também de o poder do teste estimado ser maior do que o mínimo sugerido de 0,80 ou 80% e neste caso o pesquisador(a) teria a possibilidade de reduzir o tamanho amostral até chegar ao mesmo.

Atualmente é muito relevante a possibilidade de se reduzir o tamanho amostral sem perder a confiabilidade nas conclusões do ensaio, como verificado nas exigências das Comissões de Ética no Uso de Animais (CEUA), que atentam para o princípio dos 3 R's: Replacement (Substituição), Reduction (Redução) e Refinement (Refinamento) no uso de animais para ensino e pesquisa científica.

Overall F Test for One-Way ANOVA

Fixed Scenario Elements	
Method	Exact
Alpha	0.05
Group Means	0.32 0.4 0.21
Standard Deviation	0.26
Sample Size per Group	5

Computed Power	
Power	0.138

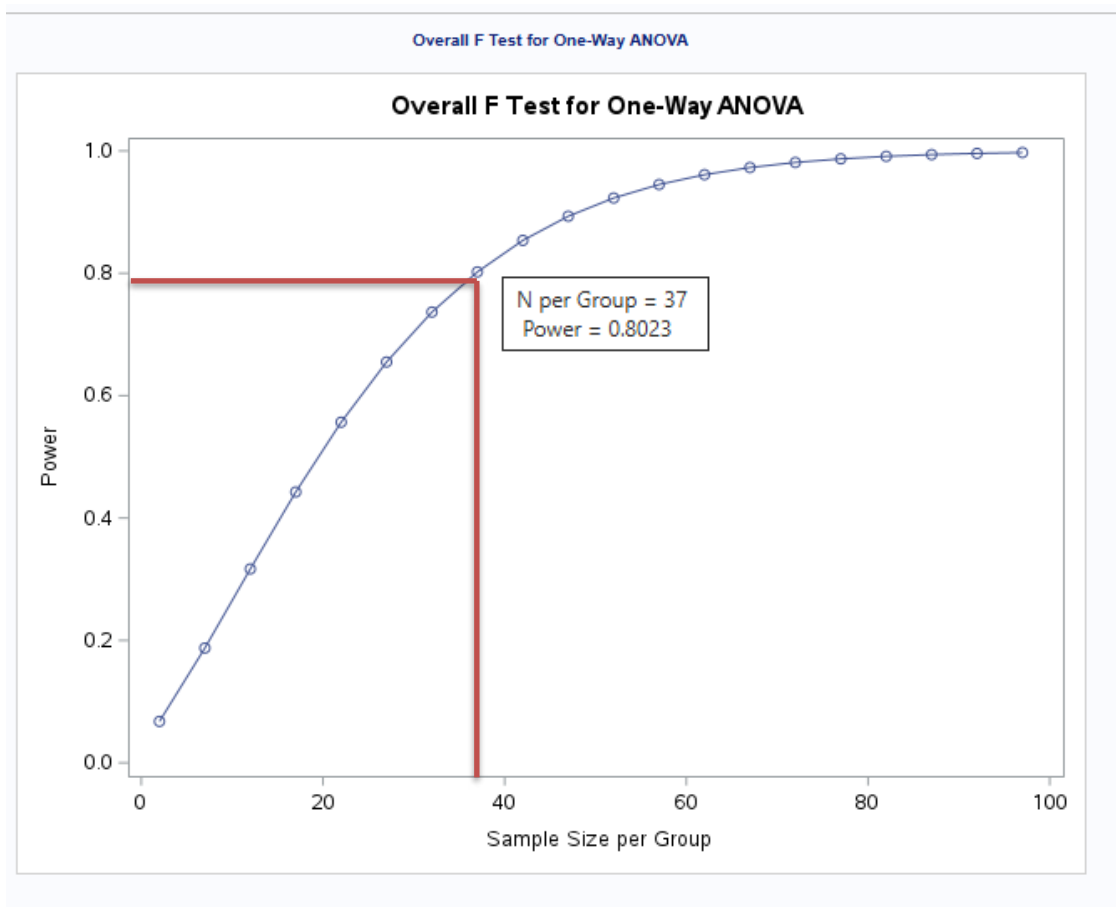


Figura 7 – Aba *Results* do software SAS® Studio

6 CONSIDERAÇÕES FINAIS

Conhecimentos teóricos fundamentais são necessários para compreensão e estimativas do tamanho amostral, que está relacionado com o tipo de análise, Poder do teste, Tamanho do efeito, P valor, Erro tipo I e tipo II e medidas descritivas de dispersão.

A definição do tamanho amostral se torna facilitada com uso de software, podendo-se utilizar dados de estudos já publicados, projetos piloto ou do próprio ensaio experimental.

Além do P valor (que é tradicionalmente apresentado como parte dos resultados), sugere-se a inclusão das estimativas de Poder do teste e/ou Tamanho do efeito na descrição de resultados de variáveis dependentes de ensaios zootécnicos, com intuito de tornar mais abrangente a avaliação e interpretação de resultados/ conclusões por parte dos leitores, bem como melhorar a percepção da qualidade experimental e definição mais precisa do tamanho amostral.

REFERÊNCIAS

- ALVES, A. Estatística aplicada: análise de dados – Volume 1. Aprender Estatística Fácil: 2021, 180p.
- ARIFIN, W.N.; ZAHIRUDDIN, W.M. Sample size calculation in animal studies using resource equation approach. **Malaysian Journal of Medical Science**. v. 24, p.101–105, 2017.
- Associação Brasileira de Zootecnistas – ABZ. **Ranking aponta Brasil como 2º país que mais produz conhecimento científico na Zootecnia**. Disponível em: <https://abz.org.br/blog/ranking-aponta-brasil-como-2o-pais-que-mais-produz-conhecimento-cientifico-na-zootecnia/>. Acesso em: 29/08/2024.
- CABRAL, A.M.D.; SANTOS, G.C.L.; CARVALHO, F.F.R. et al. Métodos estatísticos aplicados à experimentação para avaliação da produção de leite. **Research, Society and Development**, v. 10, n. 11, e464101119737, 2021.
- COHEN, J. **Statistical power analysis for behaviour science**. 2ed. New York: Lawrence Erlbaum Associates, 1988. 567 p.
- FIELD, A; MILES, J. **Discovering statistics using SAS**. SAGE, London. 2010. 720p.
- FRANÇA, A.A.; CABRAL, A.M.D.; VALE, P.A.C.B. et al. Delineamentos experimentais utilizados na avaliação da produção de leite. **Research, Society and Development**, v. 12, n. 4, e17612441125, 2023.
- GOMES, F.P. **Curso de estatística experimental**. 13 ed. ESALQ: Piracicaba, 1990. 467 p.
- GREEN, S.B. How many subjects does it take to do a regression analysis? **Multivariate Behavioural Research**. v. 26, p. 499-510, 1991.
- LÚCIO, A.D.; LOPES, S.J.; STORCK, L. et al. Características experimentais das publicações da Ciência Rural de 1971 a 2000. **Ciência Rural**, v.33, n.1, p. 161-164, 2003.
- OISETH, S.; JONES, L.; MAZA, E. **Potência estatística**. Atualizado em 32/10/2022. Disponível em: https://www.lecturio.com/pt/concepts/potencia-estatistica/#lecturio-toc_Defini%C3%A7%C3%A3o%20e%20Import%C3%A2ncia. Acesso em: 29/08/2024.
- RICHARDSON, C.R.; NUNNERY, G.A.; WESTER, D.B. et al. Power of test considerations for beef cattle experiments: a review. **Journal of Animal Science**. v. 82, E-Suppl:E214-222. 2004.
- SERDAR, C.C.; CIHAN, M.; YÜCEL, D. et al. Sample size, power and effect size revisited: simplified and practical approaches in pre-clinical, clinical and laboratory studies. **Biochemia Medica (Zagreb)**, v. 31, n. 1, 010502. 2021.
- VAZ, M.A.B. **Poder estatístico e coeficiente de variação em experimentos com bovinos de corte**. Tese Doutorado. Programa de Pós Graduação em Zootecnia – UFSM, 2016. 91p.

CAPÍTULO IV

SAS VIYA: DESCUBRA INSIGHTS COM SAS VISUAL ANALYTICS

Tais Silva⁴

⁴ SAS Software, Brasil. E-mail: tais.silva@sas.com

Neste capítulo, estudaremos a ferramenta analítica de visualização de dados do SAS Viya. O SAS Visual Analytics é a plataforma que permite as organizações a criarem e visualizarem relatórios interativos, explorarem dados e descobrirem insights com análises avançadas.

1 INTRODUÇÃO

No momento atual em que vivemos, cada dia mais *data-driven*, a capacidade de transformar dados brutos em insights acionáveis é fundamental para o sucesso de qualquer organização. A visualização de dados persiste como uma ferramenta poderosa nesse contexto, permitindo que analistas e tomadores de decisão compreendam complexas relações e padrões de maneira ágil e altamente intuitiva.

A plataforma do SAS Viya, integra o SAS Visual Analytics, representado dentro da esteira de ciclo de vida analítico o módulo de exploração dos dados. Com uma arquitetura moderna e avançada, esta ferramenta oferece um conjunto abrangente de recursos *low-code e drag-and-drop* para a criação de visualizações acessíveis e interativas que vão muito além de simples gráficos e tabelas, incluindo a geração de modelos de aprendizado de máquina – sem a geração de uma linha de código, importação de seus próprios dados, data quality e muito mais.

Com sua eficiente integração com outras ferramentas sob o ciclo de vida analítico do SAS Viya, como o SAS Studio ou até mesmo o SAS Model Studio, que facilita não somente a preparação dos dados e a modelagem, como também a orquestração entre diferentes equipes e distintos tipos de personas. Promovendo confiança, reutilização e consistência. Proporcionando agilidade na geração de insights relevantes, atendendo às necessidades do negócio. E escalável para o atendimento de necessidades futuras.

O SAS® Viya™ combina a facilidade de uma interface simples de utilizar com a velocidade dos Serviços Analíticos de Cloud SAS ou (Cloud Analytics Services CAS), o coração do SAS Viya, responsável por processar os dados em paralelo. Esta combinação proporciona uma plataforma que é ao mesmo tempo ágil e escalável, permitindo que a geração de insights seja rápida e eficaz, ajustando-se às demandas dinâmicas do mercado e exigências de um negócio.

Além disso, o SAS Visual Analytics oferece uma experiência de usuário altamente flexível e acessível. A plataforma é projetada para suportar diversos formatos de acesso, o que significa que os usuários podem interagir com suas análises e visualizações tanto através de interfaces web quanto móveis. Isso garante que as informações estejam sempre disponíveis, permitindo uma tomada de decisão em tempo real, independentemente do dispositivo ou da localização do usuário.

Neste capítulo, exploraremos em detalhes como o SAS® Viya™ e o SAS® Visual Analytics podem transformar a maneira como você interage com seus dados, oferecendo uma visão abrangente de suas capacidades, funcionalidades e melhores práticas para maximizar o valor de suas análises.

2 DADOS

O SAS tem a missão de transformar um mundo de dados em um mundo de inteligência. E em um mundo moderno dos negócios, a qualidade e a gestão eficaz dos dados são essenciais para a tomada de decisões bem direcionadas e estratégicas. É o começo da criação do mundo de inteligência para o mercado.

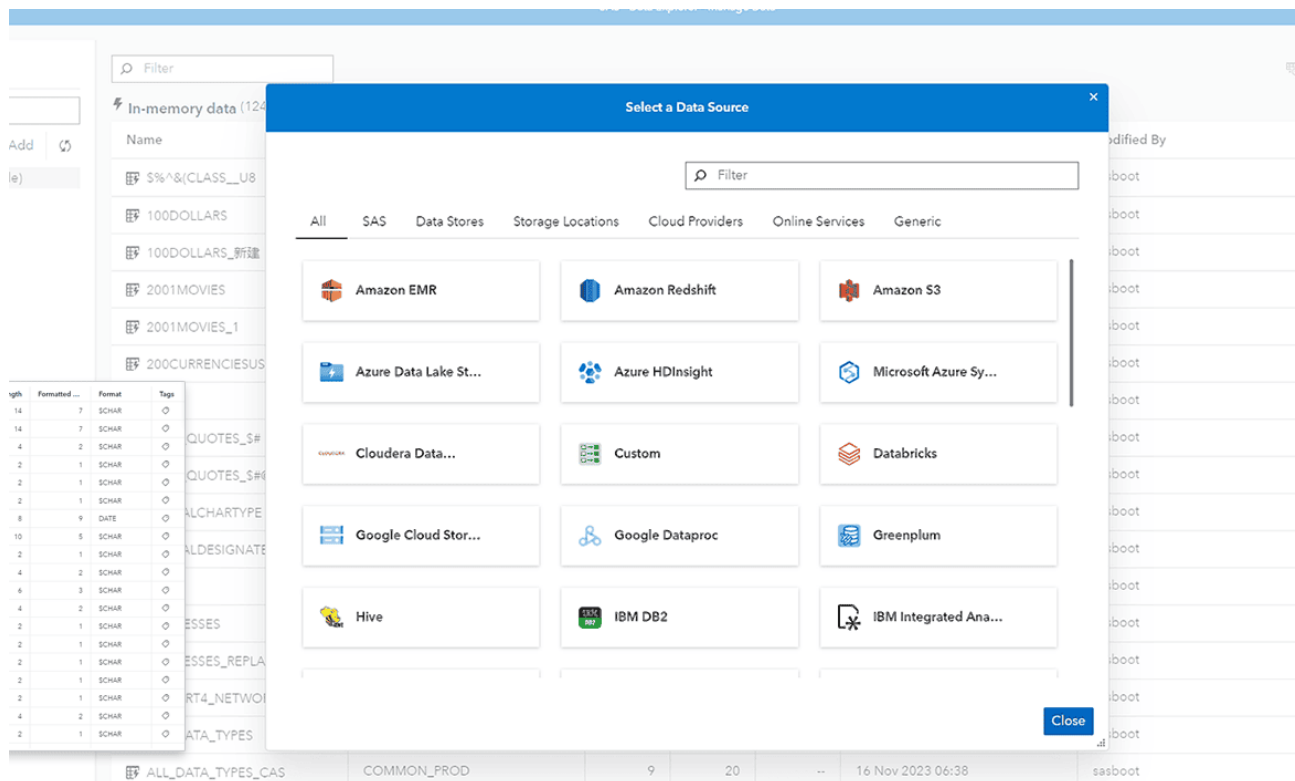
No SAS Viya, a gestão de dados é facilitada por um conjunto de ferramentas e recursos integrados que permitem aos usuários importar, preparar e analisar dados de maneira eficiente. O SAS Visual Analytics, como parte desta plataforma, desempenha o papel na visualização e interpretação dos dados.

Há diversas opções para a integração e importação de dados. A plataforma é projetada para se conectar a uma ampla gama de fontes de dados, incluindo bancos de dados relacionais, arquivos CSV, Excel, serviços web e até mesmo fontes de dados na nuvem. Todo o processo de importar seus dados para o SAS Viya também é feito por interfaces intuitivas.

Essa flexibilidade é crucial para garantir que os dados possam ser facilmente integrados e preparados para as análises. As principais opções incluem:

- Conectores de Banco de Dados

O SAS Viya possui conectores nativos para bancos de dados relacionais populares como SQL Server, Oracle, Hadoop, RDBMS, S3, SAP Hana, Snowflake, Salesforce, MySQL e muito mais. Isso facilita a integração direta com sistemas de gestão de banco de dados existentes.



- **Importação de Arquivos**

Arquivos CSV, Excel e outros formatos comuns podem ser facilmente carregados para a plataforma, permitindo uma integração rápida e eficiente de dados.

- **Serviços Web e APIs**

A plataforma também suporta a integração com serviços web e APIs, permitindo a importação de dados de fontes externas e serviços em nuvem.

A segurança e a governança dos dados são prioridades no SAS, garantindo que as informações estejam protegidas e as práticas de conformidade sejam seguidas:

- **Segurança de Dados**

A plataforma inclui recursos de segurança para proteger os dados contra acesso não autorizado e garantir a privacidade das informações.

- Auditoria e Controle

Funcionalidades de auditoria permitem rastrear alterações nos dados e nas análises, assegurando a conformidade com as políticas de governança.

Com essas ferramentas e recursos, o SAS Viya proporciona uma solução abrangente para a gestão de dados, desde a integração e importação até a segurança e governança, facilitando a análise eficiente e a geração de insights a partir de dados complexos.

3 EXPLORAÇÃO

A exploração de dados é uma etapa fundamental no processo analítico, onde os dados são examinados para descobrir padrões, tendências e insights que podem não ser imediatamente aparentes.

O SAS Visual Analytics é projetado para fornecer uma experiência de exploração de dados altamente interativa. As principais características incluem:

- Interfaces Intuitivas

A interface de arrastar e soltar (drag-and-drop) permite que os usuários criem visualizações e relatórios de forma fácil e rápida. Isso elimina a necessidade de codificação complexa e torna a exploração de dados acessível a todos os níveis de usuários.

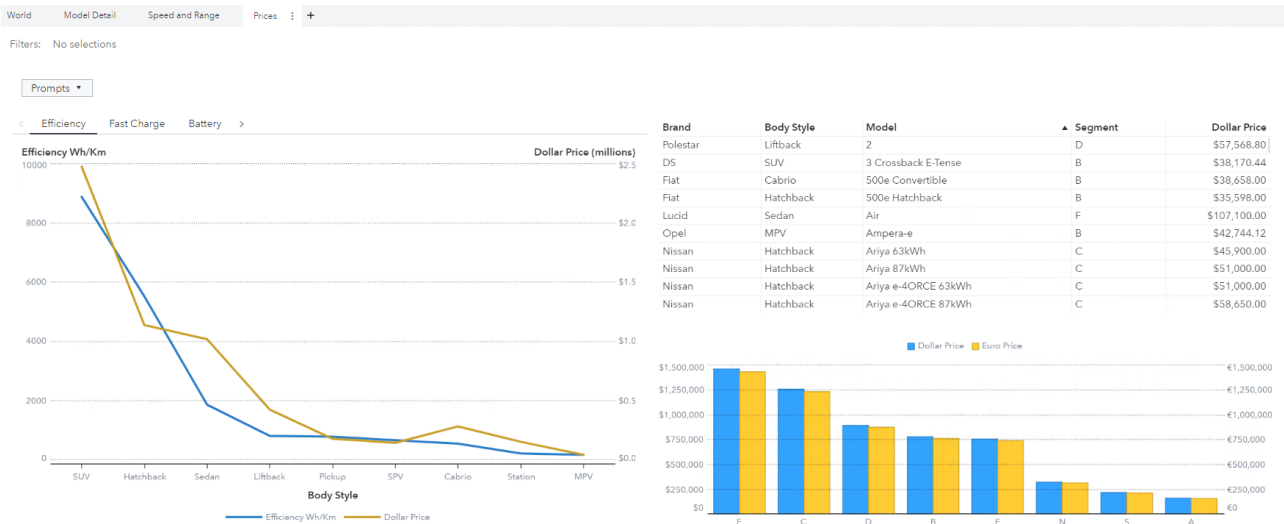
- Exploração Interativa

É possível interagir diretamente com as visualizações para filtrar, segmentar e explorar os dados em diferentes níveis de granularidade. Por exemplo, clicar em um gráfico pode atualizar outros gráficos e tabelas no mesmo painel, proporcionando uma visão holística e detalhada dos dados.

O SAS Visual Analytics oferece uma ampla gama de ferramentas de visualização que são essenciais para a exploração de dados. Entre as opções disponíveis estão:

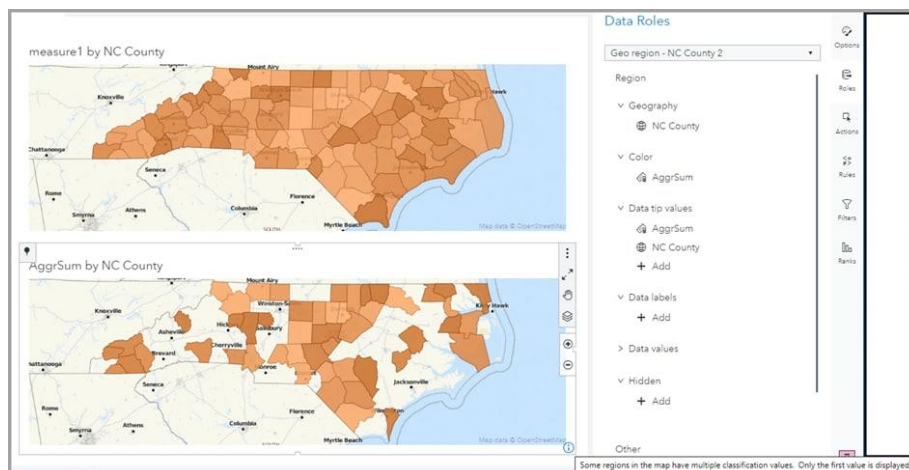
- Gráficos e Tabelas

Os gráficos são fundamentais para a visualização de dados, e no SAS Visual Analytics você tem acesso a uma ampla variedade de gráficos. Diversos tipos como gráficos de barras, linhas, dispersão e áreas, permitem a visualização de diferentes aspectos dos dados. Tabelas dinâmicas e cruzadas oferecem uma forma detalhada de examinar e comparar dados.




- Mapas Geoespaciais

Quando os dados possuem dimensão geográfica, os mapas são uma ferramenta poderosa para melhor visualização e compreensão dos dados. Eles permitem a visualização em contextos espaciais, ajudando a identificar padrões e tendências relacionadas à localização. Muito útil para identificar padrões regionais, analisar dados de vendas por localização e entender a distribuição geográfica de variáveis importantes.



- Visualizações de Tendências

Para análises que envolvem dados ao longo do tempo, o SAS Visual Analytics oferece opções especializadas para visualizações de séries temporais e tendências. Gráficos de linha e áreas podem mostrar a evolução de métricas ao longo dos períodos, enquanto técnicas de suavização e previsão ajudam a identificar tendências e antecipar futuros comportamentos com base nos dados históricos.



4 ANÁLISES

Como já vimos anteriormente, uma das forças do SAS Visual Analytics é a integração entre análise e visualização. As análises podem ser facilmente incorporadas em visualizações interativas, permitindo que os usuários vejam os resultados de suas explorações em tempo real. As capacidades analíticas do SAS são projetadas para facilitar o uso, permitindo que os analistas de negócios criem e utilizem modelos analíticos de forma independente, sem a necessidade de adquirir novas habilidades ou envolver a equipe de TI. Dessa forma, os usuários de negócios obtêm as respostas que necessitam quando precisam, e os especialistas não ficam sobrecarregados com constantes solicitações de análises.

O SAS Visual Analytics permite que os analistas de negócios avaliem rapidamente possíveis resultados ou estimem parâmetros desconhecidos para apoiar decisões mais informadas. Suas funcionalidades poderosas, porém, de fácil utilização, incluem:

- Previsão Automatizada

O método de previsão mais adequado é selecionado de acordo com os dados disponíveis. Mesmo usuários iniciantes conseguem realizar previsões de maneira confiável.

- Busca de Metas

Determine os valores dos fatores subjacentes necessários para atingir a previsão alvo. Isso facilita a definição de metas e o planejamento estratégico.

- Árvores de Decisão

Crie uma segmentação hierárquica dos dados de entrada com base em uma série de regras aplicadas a cada observação. Essa técnica ajuda a entender as decisões e o impacto das variáveis.

- Diagramas de Rede

Visualize como os dados complexos estão interconectados. Essa representação facilita a compreensão das relações e dependências entre diferentes elementos.

- Análise de Caminho

Visualize as relações entre uma sequência distinta de eventos. A análise de caminho exhibe o fluxo de dados de um evento para outro como uma série de trajetórias, ajudando a entender o fluxo de processos e eventos.

- Análise de Texto

Aplique análise de sentimento a vídeos do YouTube, streams do Twitter, postagens no Facebook, dados do Google Analytics ou comentários de clientes para obter uma visão rápida do que está sendo discutido nas mídias sociais e além. O SAS Visual Analytics oferece mais do que simples nuvens de palavras que mostram a frequência de termos; ele categoriza o conteúdo para determinar quais tópicos

são mais relevantes e identifica sentimentos em tópicos e documentos, fornecendo caminhos claros para uma exploração mais aprofundada.

Com essas capacidades, o SAS Visual Analytics não apenas simplifica o processo de análise, mas também permite uma compreensão mais profunda e eficaz dos dados, facilitando a tomada de decisões estratégicas e operacionais.

A análise exploratória, por exemplo, é um processo iterativo e interativo que envolve a examinação dos dados para descobrir os padrões, anomalias e insights. Entender os dados antes de aplicar modelos analíticos mais complexos. O SAS oferece várias funcionalidades para ajudar na descoberta de padrões e na geração de hipóteses:

a) Análise Descritiva

Estatísticas descritivas como médias, medianas e desvios padrão ajudam a resumir e entender as principais características e variabilidade dos dados. Essas medidas fornecem uma visão geral dos dados e são essenciais para preparar o terreno para as análises mais profundas.

b) Análise de Correlação

Auxilia a identificar e quantificar a relação entre variáveis. E o SAS Visual Analytics permite a operação do cálculo dos coeficientes de correlação e visualizar essas relações por meio de gráficos de dispersão e matrizes de correlação. Entender como variáveis estão inter-relacionadas pode revelar insights sobre dependências e influências mútuas.

c) Segmentação de Dados

A capacidade de segmentar dados envolve dividir conjunto, grupos ou categorias de dados com base em características comuns. Podendo ser realizada dentro do SAS Visual Analytics através de filtros e grupos dinâmicos, permitindo uma análise mais detalhada de diferentes subgrupos. Isso é útil para identificar comportamentos distintos, padrões específicos e insights segmentados.

Para maximizar o valor dos insights descobertos durante a exploração de dados, o SAS Visual Analytics oferece recursos de personalização e compartilhamento que facilitam a comunicação e a colaboração.

Os usuários podem personalizar relatórios e dashboards para atender às suas necessidades específicas. Isso inclui a seleção de visualizações apropriadas, a configuração de filtros e a adaptação do layout para destacar as informações mais relevantes.

Esta personalização assegura que os insights sejam apresentados de maneira que melhor suporte a tomada de decisão.

O SAS Visual Analytics também permite que os usuários compartilhem relatórios e dashboards com colegas e partes interessadas. A plataforma oferece opções para compartilhar visualizações de forma segura e controlada, facilitando a colaboração e a discussão em torno dos dados e insights.

A capacidade de compartilhar descobertas ajuda a promover uma cultura orientada por dados e a alinhar equipes em torno de objetivos comuns.

A exploração de dados é uma etapa essencial no processo analítico, permitindo que os usuários descubram e compreendam insights valiosos que podem informar a tomada de decisões. O SAS oferece um conjunto abrangente de ferramentas para a exploração interativa e avançada de dados. Com suas capacidades de visualização, análise e personalização, a plataforma te capacita a transformar dados brutos em insights acionáveis e a compartilhar essas descobertas de maneira eficaz.

Ao aproveitar o SAS Visual Analytics, você pode obter uma compreensão mais profunda dos dados e usar essas informações para impulsionar estratégias e decisões informadas.

5 PRODUZIR INSIGHTS

A capacidade de produzir insights valiosos a partir dos dados é o objetivo central de qualquer análise de dados. No SAS, já abordamos como a produção de insights é um processo que envolve a combinação de análise avançada com visualização interativa. A plataforma oferece várias funcionalidades que permitem aos usuários transformar dados brutos em informações significativas e acionáveis.

Com capacidades especializadas de processamento de linguagem natural (NLP) e machine learning, o SAS permite a análise de grandes volumes de texto e a construção de modelos preditivos que aprendem e se adaptam com base em novos dados.

Até mesmo usuários sem experiência analítica podem usar o SAS Visual Analytics para obter insights precisos. Usuários não técnicos podem criar e alterar consultas simplesmente selecionando itens de uma barra lateral ou filtrando e agrupando dados dinamicamente. A funcionalidade de análise automatizada determina quais variáveis contribuem para um resultado e uma explicação simples em linguagem natural destaca insights essenciais.

O *autocharting* do SAS seleciona a visualização que melhor se adapta ao tipo de dados escolhido para a criação do relatório. Usuários analiticamente experientes podem usar técnicas de visualização para identificar tendências e obter insights aprofundados mais rapidamente. Isso elimina muitos dos processos cotidianos de tentativa e erro atualmente usados para identificar áreas que precisam de análise mais aprofundada.

Além do mais, o SAS Viya é projetado para se integrar perfeitamente com ferramentas do Microsoft 365, como o Excel, facilitando o acesso e compartilhamento de dados e insights. Os resultados e visualizações gerados no SAS podem ser exportados diretamente, por exemplo, para o Excel. Isso permite que os usuários compartilhem análises e relatórios em um formato amplamente utilizado e familiar para a maioria das partes interessadas.

Insights e relatórios gerados no SAS Viya podem ser compartilhados diretamente através do Microsoft Teams e SharePoint. Isso promove a colaboração entre equipes e garante que todos os membros da organização tenham acesso às informações necessárias. A plataforma oferece funcionalidades de segurança que permitem controlar quem pode acessar, visualizar e modificar dados e relatórios. Isso é crucial para garantir a confidencialidade e integridade das informações.

A produção de insights no SAS Viya é uma experiência poderosa e eficiente, que combina análise avançada com visualização interativa. A integração com ferramentas do Microsoft 365, como o Excel, Teams e SharePoint, amplia as capacidades de acesso e compartilhamento, tornando a comunicação e colaboração

mais fluídas e eficazes. A facilidade de importar e exportar dados, junto com a automação de relatórios e as robustas funcionalidades de segurança, assegura que os usuários possam transformar dados brutos em insights valiosos e compartilhá-los de maneira segura e eficaz.

6 BOAS PRÁTICAS

Sabemos que criar um relatório no SAS® é muito fácil e que podemos criar relatórios impressionantes com apenas alguns cliques.

No entanto, não basta apenas criar. Devemos torná-lo eficaz. Para construir algo assim, perguntas podem aparecer como:

1. Como construí-lo?
2. O que significa um relatório/painel eficaz?
3. Como usar meus dados de maneiras que signifiquem algo real?
4. Como fazer meu painel ajudar na tomada de decisões?

Primeiro, devemos entender nossos dados e, em seguida, transformá-los nas informações de que precisamos.

a. Contexto

A jornada da visualização de dados não se inicia com a escolha de um gráfico ou a criação de um dashboard. Muito antes de se comunicar através dos dados, a atenção de quem vai construir o painel deve ser voltada para o contexto da informação que gostaria de transmitir. É como montar um quebra-cabeça: cada peça (dado) só faz sentido quando está inserida no contexto correto.

Pense que o contexto ajudará o usuário a entender as informações à primeira vista, sem precisar investigar por muito tempo. O contexto é a moldura que dá significado aos dados. Permitindo compreender rapidamente sem necessidade de longas explicações, identificar o público-alvo adaptando a linguagem, nível de detalhamento e garantindo que a mensagem seja altamente eficaz e a definir o objetivo levantando questionamentos como, qual a pergunta que a visualização deve responder ou qual a tomada de decisão que se espera do usuário após interagir com o painel.

Também é importante ter a habilidade de contar histórias com dados, mais conhecido como a técnica do *storytelling*. Com essa técnica, as apresentações vão muito além de um grupo de dados organizados em um painel, ao transformar dados em narrativas, engajamos o público de forma mais profunda e memorável. A história ajuda a simplificar a complexidade dos dados, apresentando contextos simples e fáceis de entender.

E o SAS Visual Analytics se destaca ao facilitar tanto a compreensão do contexto quanto a criação de narrativas poderosas.

b. Simplicidade

Dizem que a simplicidade é a alma da elegância e, acredito que ao tratar da visualização de dados, não haveria particularidades. A simplicidade se torna um atributo essencial quando a ideia de comunicação necessita agir de forma clara e eficaz.

Os atributos podem ser usados estrategicamente de duas maneiras:

1. Primeiro, eles podem ser usados para ajudar a direcionar a atenção do seu público para onde você quer que eles se concentrem.
2. Segundo, podem ser usados para criar uma hierarquia visual de elementos, para conduzir seu público através das informações que você deseja comunicar ou quer que eles entendam.

Resumindo, a importância da simplicidade se dá por três pilares: foco, clareza e memorabilidade.

O foco ajuda a reduzir a complexidade visual, direciona o público para os insights mais relevantes e importantes, evitando distrações e facilitando a compreensão.

A clareza garante que a mensagem seja transmitida de forma clara e concisa, evitando as interpretações equivocadas e diminuindo o tempo de interação do usuário ao relatório. O que diversas vezes é crucial ao se tratar de usuários tomadores de decisão.

E a memorabilidade é, basicamente, a valorização do seu relatório. O quanto é fácil de lembrar. Isto aumenta o impacto da comunicação.

Para alcançar a simplicidade é aconselhável que opte por minimizar o número dos tipos visuais e use as representações mais condensadas, é importante entender quantos visuais existem e o que eles significam, valorizando o ser coerente e visualmente agradável, para representar as prioridades de destaque.

Em resumo, a simplicidade não significa falta de sofisticação. Ao contrário, ela é a base para que a tomada de decisão e a impulsão de uma nova ação seja eficaz. Ao priorizar a clareza, coerência e relevância,

O estilo e a comunicação também são muito importantes quando almejamos ser claros e concisos com a informação que queremos transmitir. Ao dominar a arte da simplicidade, você estará um passo à frente na criação de visualizações que realmente fazem a diferença.

c. Audiência

A produção de dashboards também exige uma profunda compreensão do público-alvo. Ao projetar, é fundamental considerar quem são os usuários e quais são as suas necessidades, expectativas e conhecimentos prévios.

O ponto chave de conhecer o público se dá pelos fatores de personalização, engajamento e credibilidade. Ao adaptar, você garante que a mensagem seja relevante. Visualizações interativas e, principalmente, intuitivas convidam o usuário a explorar os dados e a descobrir insights por conta própria. E, ao demonstrar que você entende as necessidades do seu usuário, você aumenta a credibilidade do seu trabalho.

Certifique-se e seja específico sobre quem eles são, algumas dicas de como definir seu público-alvo são:

- Faça uma pesquisa de persona ou perfil demográfico: idade, gênero, educação, ocupação.
- Conhecimento técnico: o nível de familiaridade com dados e, principalmente, a ferramenta de análise.
- Interesses: questione, quais informações são mais relevantes para o público?
- Objetivos: tenha claro o que o público espera alcançar com a visualização.

Um exemplo prático para cada tipo de usuário:

- Executivos: C-levels que buscam visões gerais, informações de forma rápida e insights estratégicos = foque em métricas-chave utilize gráficos de alto nível
- Analista de negócio: Precisam de detalhes e mais flexibilidade para explorar os dados = ofereça opções de personalização, como filtros e ferramentas de análise mais avançada.
- Público diverso de uma mesma empresa: visualizações simples e intuitivas de X conjunto de dados = priorize estética e interatividade.

Ao entender as necessidades e expectativas, é possível criar visualizações que não apenas transmitem as informações, mas também engajam. Em resumo, o usuário é o centro de toda a visualização de dados.

d. Visual eficaz

Podemos tratar este tópico como a arte de se comunicar com dados. Cada tipo de gráfico possui suas particularidades e é mais adequado para determinados tipos de dados e objetivos. A chave está em selecionar aquele que melhor representa a história queira contar.

Escolher um gráfico é o primeiro passo, entretanto outros elementos também são primordiais para uma visualização mais eficaz.

Trabalhe com títulos claros e concisos, eles ajudam a resumir a mensagem principal. Eixos claramente rotulados também facilitam a interpretação dos dados. Legendas autoexplicativas, que sejam fáceis de entender. Destaques visuais, cores, tamanhos e formas destacam os pontos mais importantes da sua visualização. E, a depender do nível de complexidade, é válido adicionar comentários que trabalhem para contextualizar os dados e auxiliar o usuário a compreender a visualização sem maiores implicações.

Tenha em mente que eficaz é quase afetivo. Trabalhar com uma narrativa, cores coerentes, simplicidade e interatividade ajuda a complementar a transformação de seus dados em uma história relevante.

e. Foco

Guie o olhar do seu usuário. Não apenas apresente os dados, guie o seu usuário a focar na informação mais importante.

Para alcançar esse objetivo é fundamental manter o foco narrativo, cada visualização deve contar uma parte de uma história maior. Conduzindo de um ponto ao outro. Isso é possível utilizando técnicas de priorização da informação, como tamanho, cor, hierarquia, posição e até mesmo o tipo de gráfico. Características importantes para destacar elementos mais relevantes e guiar o usuário por onde começar. Evite sempre sobrecarregar visualizações com detalhes desnecessários. Lembre-se que a simplicidade é efetiva.

O foco é essencial para criar visualizações eficazes. E uma sequência lógica ajuda o usuário a construir uma narrativa mental e a conectar os pontos sozinho. E o SAS Visual Analytics oferece uma ampla variedade de ferramentas e opções para criar visualizações focadas e eficazes.

Em resumo, ao direcionar o usuário para as informações mais importantes, você garante que sua mensagem não só seja efetivamente compreendida como também lembrada.

f. Pense como um Designer

A forma segue a função. O processo de construção de um dashboard também é um processo criativo que exige um bom domínio dos princípios do design. Ao sugerir pensar como um designer, você pode deixar sua criatividade transformar os seus dados em histórias visuais que intuitivamente engajam, informam e elevam a tomada de decisão.

E o design de uma visualização deve ser orientado por sua função para estar em harmonia. Ou seja, a forma visual deve facilitar a compreensão e a interação com os dados.

Para ajudar neste processo é importante escolher uma boa ferramenta, o SAS Visual Analytics, por exemplo, oferece uma variedade de gráficos que podem ser adaptadas a diferentes tipos de dados e públicos. É uma ferramenta que possui diversas formas de inovar, mantendo a coerência e a consistência.

Todas as práticas mencionadas anteriormente auxiliam a desenvolver técnicas de forma artística e criativa. Portanto, ao escolher a plataforma com

recursos que ajudam a criar visualizações mais impactantes, não tenha medo de experimentar e criar designs únicos e inovadores.

7 CASOS DE USO

O SAS Viya 4 e o SAS Visual Analytics têm demonstrado seu valor em uma variedade de setores, ajudando organizações a transformar dados brutos em insights acionáveis e melhorar a tomada de decisões. Ao seguir a leitura, exploraremos casos de uso que ilustram como essas ferramentas podem ser implementadas com eficácia por distintas áreas de negócios.

Analisaremos como essas soluções abordam desafios específicos e geram benefícios tangíveis para as organizações.

Desafio: Uma operadora de telecomunicações enfrenta desafios com a análise de grandes volumes de dados provenientes de suas operações e interações com clientes. A empresa precisa de uma solução que possa integrar dados de diversas fontes, melhorar a visualização das informações e permitir tomar decisões mais informadas.

Solução: SAS Viya 4 e o SAS Visual Analytics para modernizar sua infraestrutura de análise de dados. A implementação incluiu:

- **Integração de Dados:** Conectores nativos do SAS Viya foram usados para integrar dados de diferentes sistemas, incluindo CRM, dados de rede e informações de uso de clientes.
- **Visualização Interativa:** Utilizando o SAS Visual Analytics, a empresa criou dashboards interativos que permitiram uma visualização consolidada das métricas de desempenho e da experiência do cliente.
- **Análises:** A capacidade analítica do SAS Viya permite à operadora monitorar eventos e tendências conforme eles ocorrem, ajustando suas estratégias e operações de forma ágil.

Resultados:

- **Redução do Tempo de Resolução de Problemas:** A capacidade de visualizar e identificar rapidamente problemas ajuda a reduzir o tempo de resolução de questões técnicas e operacionais.
- **Melhoria na Experiência do Cliente:** Com insights mais profundos sobre o comportamento e as preferências dos clientes, a operadora é capaz de personalizar ofertas e melhorar a experiência do cliente.
- **Otimização de Recursos:** A análise avançada auxilia a otimizar o uso dos recursos da rede, resultando em uma melhor alocação e redução de custos operacionais.

Desafio: Uma instituição financeira precisa enfrentar desafios relacionados à análise de risco e conformidade. A organização busca uma solução que possa integrar dados financeiros complexos, realizar análises preditivas e gerar relatórios detalhados para atender aos requisitos regulatórios.

Solução: SAS Viya 4 e o SAS Visual Analytics para melhorar a gestão de risco e a conformidade:

- **Modelagem Preditiva:** Usando as ferramentas de modelagem estatística e preditiva do SAS Viya, a organização desenvolve modelos para prever riscos financeiros e identificar possíveis fraudes.
- **Automação de Relatórios:** A plataforma automatiza a geração de relatórios regulatórios, garantindo que a instituição atenda aos requisitos de conformidade de forma eficiente e precisa.
- **Integração de Dados:** O SAS Viya integra dados de diversas fontes financeiras e operacionais, permitindo uma visão abrangente e consolidada das exposições ao risco.

Resultados:

- **Redução de Riscos:** Os modelos preditivos ajudam a identificar e mitigar riscos potenciais antes que se materializassem, melhorando a segurança financeira.

- **Eficiência Operacional:** A automação dos processos de geração de relatórios reduz significativamente o tempo e os recursos necessários para a conformidade regulatória.

- **Visão Consolidada:** A integração de dados proporciona uma visão única das exposições ao risco, facilitando a tomada de decisões informadas.

Desafio: Uma organização de saúde enfrenta dificuldades na análise de dados clínicos e administrativos para melhorar os resultados dos pacientes e otimizar os processos internos. A necessidade é de uma solução que possa integrar dados de diferentes fontes e fornecer insights para a melhoria contínua da qualidade dos cuidados.

Solução: SAS Viya 4 e o SAS Visual Analytics para transformar seus dados clínicos e administrativos em insights acionáveis:

- **Análise de Dados Clínicos:** A plataforma permite a integração e análise de dados de registros eletrônicos de saúde, exames laboratoriais e dados de operações.

- **Visualização de Indicadores de Qualidade:** Dashboards interativos para monitorar indicadores de qualidade dos cuidados e desempenho dos profissionais de saúde.

- **Segurança e Conformidade:** Análise de dados que respeite normas rigorosas de privacidade e segurança.

Resultados:

- **Melhoria na Qualidade dos Cuidados:** Insights detalhados ajudam a identificar áreas de melhoria na prestação de cuidados e a implementar práticas baseadas em dados.

- **Otimização de Processos:** A análise de dados administrativos resulta em processos mais eficientes e melhor alocação de recursos.

- **Aumento da Satisfação do Paciente:** A organização é capaz de ajustar suas práticas com base no feedback dos pacientes e nos dados de desempenho, resultando em uma experiência mais satisfatória para os pacientes.

Desafio: Uma empresa de varejo enfrenta desafios em entender o comportamento dos clientes e a otimizar suas campanhas de marketing. A empresa precisa de uma solução que pudesse analisar dados de vendas, comportamento do cliente e campanhas promocionais para melhorar suas estratégias de marketing.

Solução: SAS Viya 4 e o SAS Visual Analytics para aprimorar sua estratégia de marketing e análise de vendas:

- **Análise de Comportamento do Cliente:** Analisar dados de transações e comportamento online dos clientes, identificando padrões e preferências.
- **Segmentação de Mercado:** Utilizando técnicas de segmentação, a empresa consegue criar campanhas personalizadas e direcionadas a diferentes grupos de clientes.
- **Avaliação de Campanhas:** Dashboards interativos criados para avaliar o impacto das campanhas promocionais e ajustar estratégias em tempo real.

Resultados:

- **Aumento nas Vendas:** Campanhas de marketing personalizadas e baseadas em dados resultam em um aumento significativo nas vendas e na eficácia das promoções.
- **Melhoria na Experiência do Cliente:** A segmentação permite oferecer uma experiência mais relevante e personalizada, aumentando a satisfação e a fidelidade dos clientes.
- **Eficiência na Alocação de Recursos:** A análise detalhada ajuda a otimizar a alocação de recursos de marketing e a maximizar o retorno sobre o investimento.

Os casos de uso apresentados ilustram como o SAS Viya 4 e o SAS Visual Analytics podem ser eficazes em transformar dados em insights valiosos para uma ampla gama de setores. Desde telecomunicações e serviços financeiros até saúde e varejo, as soluções do SAS têm permitido às organizações resolver desafios complexos, melhorar a tomada de decisões e alcançar resultados significativos.

A capacidade de integrar e analisar dados de diferentes fontes, juntamente com ferramentas avançadas de visualização e análise, tem sido fundamental para

ajudar essas organizações a obter uma vantagem competitiva e melhorar seus processos e resultados.

Esses exemplos demonstram o potencial do SAS Viya e do SAS Visual Analytics para gerar valor real e sustentável, oferecendo soluções eficazes para uma ampla gama de necessidades analíticas e empresariais.

8 COMUNIDADE

A comunidade do SAS Visual Analytics é dedicada a usuários focados na visualização exploratória e técnicas analíticas, preparação de dados, relatórios de painel e relatórios móveis. Usando a comunidade, você pode compartilhar suas experiências, discutir tópicos e ideias, procurar ajuda de seus colegas e compartilhar informações sobre os próximos eventos. Você pode acessar a comunidade de usuários em comunidades.sas.com/visual-analytics.

Para perguntas que requerem assistência técnica imediata, entre em contato com o suporte técnico do SAS em suporte.sas.com.

O SAS Community oferece fóruns de discussão onde usuários podem postar perguntas, compartilhar respostas e participar de conversas sobre tópicos relacionados ao SAS Viya, SAS Visual Analytics e outras soluções SAS. Esses fóruns são uma rica fonte de conhecimento prático e experiências compartilhadas.

A plataforma inclui blogs e artigos escritos por especialistas da SAS e membros da comunidade. Recursos estes que abordam uma ampla gama de tópicos, desde tutoriais e estudos de caso até análises detalhadas sobre novas funcionalidades e melhores práticas. O SAS Community disponibiliza diversas formas de conteúdo como recursos educacionais, incluindo webinars, tutoriais em vídeo e cursos online que ajudam a aprimorar suas habilidades.

A comunidade como um todo, fornece um recurso valioso para a resolução de problemas técnicos e desafios de implementação. Os usuários podem obter respostas rápidas e soluções baseadas na experiência de outros membros da comunidade. A troca de dicas ajuda os usuários a otimizar o uso das ferramentas SAS, descobrir funcionalidades menos conhecidas e melhorar a eficiência em suas análises. Oferecendo acesso a uma vasta gama de conteúdos que permitem aos

usuários aprimorar suas habilidades e conhecimentos sobre o SAS Viya e o SAS Visual Analytics.

Participar da comunidade SAS permite aos usuários fazer conexões valiosas com outros profissionais da área, facilitando oportunidades de colaboração e networking. A colaboração com outros membros da comunidade pode levar à criação de parcerias e projetos conjuntos, promovendo o desenvolvimento de novas soluções e abordagens na análise de dados.

Para tirar o máximo proveito da comunidade SAS, os usuários interessados podem participar ativamente dos fóruns de discussões. Engajando com perguntas, compartilhando suas próprias experiências e contribuindo com respostas e soluções para ajudar outros membros. Participar de eventos e webinars oferecidos pela SAS e pelos grupos de usuários para se atualizar sobre as últimas tendências e técnicas. Contribuir com artigos, blogs e tutoriais para compartilhar seu conhecimento e experiência com a comunidade. Utilizar os recursos educacionais disponíveis na comunidade para melhorar suas habilidades e se manter informado sobre novas funcionalidades e melhores práticas.

A comunidade SAS é um recurso inestimável que oferece suporte, aprendizado e oportunidades de networking para usuários das soluções SAS, incluindo o SAS Viya e o SAS Visual Analytics. A participação ativa na comunidade não só melhora a experiência e o conhecimento dos usuários, mas também contribui para o avanço contínuo da análise de dados e da ciência dos dados.

Através do compartilhamento de conhecimentos, resolução colaborativa de problemas e acesso a recursos educacionais, a comunidade SAS fortalece a capacidade dos usuários de maximizar o valor das soluções SAS e de se manterem na vanguarda da inovação tecnológica.

REFERÊNCIAS

SAS: An Introduction to SAS® Visual Analytics: How to Explore Numbers, Design Reports, and Gain Insight into Your Data. Acesse em: <https://support.sas.com/content/dam/SAS/support/en/books/introduction-to-sas-visual-analytics/excerpt.pdf>

Silva, T. C. R. (2023, August 15). *Best practices for building an analytical report on SAS Visual Analytics*. Medium. <https://medium.com/@tcrsilva/best-practices-for-building-an-analytical-report-on-sas-visual-analytics-9a350ba55419>

SAS. (2023, November 8). Extract text from a PDF file using SAS Viya. SAS Blogs. <https://blogs.sas.com/content/sgf/2023/11/08/extract-text-from-a-pdf-file-using-sas-viya/>

SAS. (2024, March 11). LLM-based digital assistant for SAS optimization. SAS Blogs. <https://blogs.sas.com/content/subconsciousmusings/2024/03/11/llm-based-digital-assistant-for-sas-optimization/>

SAS. (2024, May 31). SAS Certified Specialist: Statistics for machine learning. SAS Blogs. <https://blogs.sas.com/content/sgf/2024/05/31/sas-certified-specialist-statistics-for-machine-learning/>

SAS. (2017, June 8). SAS Visual Analytics: Un entorno único en SAS Viya. SAS Blogs. <https://blogs.sas.com/content/sasla/2017/06/08/sas-visual-analytics-un-entorno-unico-en-sas-viya/>

SAS. (2018, August 15). Transitioning from Visual Analytics 9.4 to Viya. SAS Blogs. <https://blogs.sas.com/content/sgf/2018/08/15/transitioning-from-visual-analytics-9-4-to-viya/>

SAS. (2019, February 8). Fundamentals of SAS Visual Analytics geo maps. SAS Blogs. <https://blogs.sas.com/content/sgf/2019/02/08/fundamentals-of-sas-visual-analytics-geo-maps/>

SAS. (2023, November 17). Moving SAS Visual Analytics reports between SAS Viya environments. SAS Blogs. <https://blogs.sas.com/content/sgf/2023/11/17/moving-sas-visual-analytics-reports-between-sas-viya-environments/>

SAS. (2019, May 6). Five key security features in the SAS Visual Analytics app. SAS Blogs. <https://blogs.sas.com/content/sgf/2019/05/06/five-key-security-features-in-the-sas-visual-analytics-app/>

SOBRE O AUTOR

Renius Mello: Professor da Universidade Federal de Santa Maria (UFSM), atua nas áreas de análise de alimentos, qualidade de carne e estatística. Com doutorado em Zootecnia pela Universidade Federal de Viçosa (2005-2007), desenvolve pesquisas voltadas para a inovação no processamento e preservação de alimentos. Seus estudos destacam-se por investigar o uso de tecnologias emergentes na extração de compostos bioativos, bem como na melhoria da qualidade da carne e alimentos funcionais. Também contribuiu em estudos sobre o uso sustentável de subprodutos alimentares e o desenvolvimento de filmes ativos para embalagens com propriedades antioxidantes e antimicrobianas. Sua atuação acadêmica inclui a orientação de alunos de graduação e pós-graduação, promovendo soluções inovadoras para o setor alimentício.

Paulo Santana Pacheco: Possui graduação em Zootecnia pela Universidade Federal de Santa Maria – RS (2002), mestrado em Produção Animal/Produção de Bovinos de Corte pela Universidade Federal de Santa Maria – RS (2004), doutorado em Ciência Animal pela Universidade Federal de Goiás – GO (2007) e pós-doutorado pela Universidade Federal de Goiás – GO (2008). As áreas de atuação compreendem aquelas envolvidas na produção de bovinos de corte, experimentação zootécnica e simulação estocástica.

José Dilson Francisco da Silva: Doutor em Ciência e Tecnologia dos Alimentos, com ênfase em tecnologia de produtos cárneos, pela Universidade Federal de Santa Maria (UFSM). Atualmente, é professor do Instituto Federal de Rondônia (IFRO), onde atua em áreas da química analítica e ciência e tecnologia de alimentos de origem animal.

Fernanda Cristina Breda: Possui graduação em Zootecnia pela Universidade de Marília (2000), mestrado em Zootecnia pela Universidade Federal de Viçosa (2003) e doutorado em Genética e Melhoramento pela Universidade Federal de Viçosa (2008). Atualmente é professora da Universidade Federal de Santa Maria, atuando nas áreas de Melhoramento Genético Animal, Estatística e Apicultura.

WSTAR - WORKSHOP ON STATISTICAL TOOLS AND ANALYSIS FOR SCIENTIFIC RESEARCH

O livro aborda a interconexão entre a Internet das Coisas (IoT), a Inteligência Artificial (AI) na ciência da carne e o uso do SAS Visual Analytics no SAS® Viya. O conceito de IoT é explorado, destacando como dispositivos conectados transformam setores como casas inteligentes, indústrias e saúde, além de discutir as camadas envolvidas em um projeto de IoT e as tecnologias de suporte, como computação em nuvem e aprendizado de máquina. A aplicação da AI na indústria de processamento de carnes é enfatizada, mostrando seu papel na automação, classificação de cortes, detecção de contaminações e otimização de processos para melhorar a eficiência e reduzir custos. O livro também menciona a importância do tamanho amostral em experimentação zootécnica para garantir a validade dos resultados. Por fim, o SAS® Visual Analytics é apresentado como uma ferramenta poderosa para transformar dados em insights acionáveis, permitindo uma visualização eficaz e a tomada de decisões em tempo real.

Home Editora

CNPJ: 39.242.488/0002-80

www.homeeditora.com

contato@homeeditora.com

91988165332

Tv. Quintino Bocaiúva, 23011 - Batista
Campos, Belém - PA, 66045-315

