

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

SAMUEL VICTOR SANTOS DE MATOS ALVARES

**UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA DETERMINAÇÃO E
AVALIAÇÃO DE PARÂMETROS QUE INFLUENCIAM NA ABSORÇÃO DE ÁGUA
EM CARÇAÇAS DE FRANGOS**

FRANCISCO BELTRÃO

2023

SAMUEL VICTOR SANTOS DE MATOS ALVARES

**UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS PARA DETERMINAÇÃO E
AVALIAÇÃO DE PARÂMETROS QUE INFLUENCIAM NA ABSORÇÃO DE ÁGUA
EM CARCAÇAS DE FRANGOS**

**Use of artificial neural networks to determine and evaluate parameters that
influence water absorption in chicken carcasses**

Trabalho de Conclusão de Curso de graduação
apresentado como requisito para obtenção do título
de Bacharel em Engenharia de Alimentos da
Universidade Tecnológica Federal do Paraná
(UTFPR).

Orientadora: Prof^a. Dr^a. Cleusa Inês Weber.

Coorientadora: Prof^a. Dr^a. Gracielle Johann

FRANCISCO BELTRÃO

2023



Esta licença permite download e compartilhamento do trabalho desde que sejam atribuídos créditos ao(s) autor(es), sem a possibilidade de alterá-lo ou utilizá-lo para fins comerciais. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

SAMUEL VICTOR SANTOS DE MATOS ALVARES

**UTILIZAÇÃO DE REDES NEURAI ARTIFICIAIS PARA DETERMINAÇÃO E
AVALIAÇÃO DE PARÂMETROS QUE INFLUENCIAM NA ABSORÇÃO DE ÁGUA
EM CARCAÇAS DE FRANGOS**

Trabalho de Conclusão de Curso de
Graduação apresentado como requisito
para obtenção do título de Bacharel em
Engenharia de Alimentos da Universidade
Tecnológica Federal do Paraná (UTFPR).

Data de aprovação: 08 de dezembro de 2023

Dr^a GRACIELLE JOHANN
Professor(a) do Magistério Superior
UTFPR-DV

Msc JOÃO FRANCISCO MARCHI
Professor Ens. Básico Tec. Tecnológico
UTFPR-FB

Dr RONAN CARLOS COLOMBO
Professor do Magistério Superior
UTFPR-FB

FRANCISCO BELTRÃO
2023

AGRADECIMENTOS

Gostaria de agradecer e dedicar este trabalho de conclusão de curso primeiramente a Deus que me guiou, me deu forças, paciência e perseverança para chegar até esse momento.

Minha família, principalmente minha mãe, por todo apoio, carinho e paciência durante esse período de formação.

A todos os meus amigos que fiz na universidade, que me propuseram momentos de felicidades e alegria.

Por fim agradeço a todos os professores citados que contribuíram para a elaboração deste trabalho, ao oferecer apoio em ler cada página e me orientar na obtenção do meu título acadêmico.

RESUMO

Com o aumento da produção da carne de frango e o seu consumo, o consumidor se tornou mais exigente, sendo que a qualidade da carne se tornou um fator fundamental. Entre as preocupações, se destaca a qualidade da carcaça e o excesso de água absorvida durante os processos de abate de frango e resfriamento das carcaças. Neste contexto, esse estudo buscou mensurar os impactos de parâmetros conhecidos que podem interferir na absorção de água no processo pós-abate de um frigorífico através da análise de dados em *Python*. O objetivo principal foi desenvolver um modelo preditivo utilizando redes neurais artificiais para a absorção de água em carcaças de frango, considerando variáveis: temperatura tanque de escaldagem 1° e 2° estágios; tempo de retenção no tanque de escaldagem 1° e 2° estágio; temperatura da 1°, 2° e 3° depenadeiras; peso inicial da carcaça após a sangria; temperatura inicial e final do *pré-chiller*; temperatura inicial e final do *chiller*; tempo de retenção do *pré-chiller*; tempo de retenção do *chiller*; peso final da carcaça após o *chiller*. A metodologia envolveu a coleta de dados, padronização, treinamento do modelo utilizando redes neurais, otimização, avaliação do desempenho e análise da importância das variáveis (temperatura do 1° e 2° estágio do tanque de escaldagem; temperatura inicial do *pré-chiller*; temperatura final do *pré-chiller*; temperatura da 1°, 2° e 3° depenadeira). O modelo alcançou um grau de importância de 0.004868 para a temperatura do 1° estágio do tanque de escaldagem e 0.014184 para o 2° estágio do tanque de escaldagem, 0.007995 para a temperatura inicial do *pré-chiller*, 0.004819 para a temperatura final do *pré-chiller*, 0.003780 para temperatura 1° depenadeira, 0.003487 temperatura 2° depenadeira e 0.004342 temperatura 3° depenadeira, destacando a eficácia na previsão da absorção. O presente trabalho apresentou uma correlação significativa de 0,8913 para a absorção de água em carcaças de frango. Portanto, parâmetros relacionados aos estágios de resfriamento e escaldagem demonstraram impacto na absorção. Embora promissor, o modelo demanda aprimoramentos contínuos devido à complexidade do ambiente avícola.

Palavras-chave: modelagem preditiva; processo de resfriamento; qualidade das carcaças de frango.

ABSTRACT

With the increase in chicken meat production and consumption, consumers have become more demanding, with the quality of the meat becoming a fundamental factor. Among the concerns, the quality of the carcass and the excess water absorbed during the slaughter and cooling processes stand out. In this context, this study sought to measure the impacts of known parameters that can interfere with water absorption in the post-slaughter process of a slaughterhouse through data analysis using Python. The main objective was to develop a predictive model using artificial neural networks for water absorption in chicken carcasses, considering variables: scalding tank temperature 1 and 2; retention time in scalding tanks 1 and 2; temperature of the 1st, 2nd and 3rd plucking machine; initial carcass weight after bleeding; initial and final pre-chiller temperature; initial and final chiller temperature; pre-chiller retention time; total cooling time; chiller retention time; final weight of the carcass after the chiller. The methodology involved data collection, standardization, model training using neural networks, optimization, performance evaluation and analysis of the importance of variables (temperature of the 1st and 2nd scalding tanks; initial temperature of the pre-chiller; final temperature of the pre-chiller -chiller; plucking temperature 1, 2 and 3). The model achieved an impact of 0.004868 for the temperature of the 1st scalding tank and 0.014184 for the 2nd scalding tank, 0.007995 for the initial pre-chiller temperature, 0.004819 for the final pre-chiller temperature, 0.003780 for the plucking temperature 1, 0.003487 plucking temperature 2 and 0.004342 plucking temperature 3, highlighting the effectiveness in predicting absorption. It showed a significant correlation of 0.8913 for water absorption in chicken carcasses. Therefore, parameters related to the cooling stages demonstrated an impact on absorption. Although promising, the model requires continuous improvements due to the complexity of the poultry environment.

Keywords: predictive modeling; cooling process; quality of chicken carcasses.

LISTA DE FIGURAS

Figura 1. Fluxograma padrão de abatedouro de frango	21
Figura 2. Rede Neural Simples e Rede Neural Profunda (<i>Deep Learning</i>).....	30
Figura 3. Estrutura de neurônios da MLP com N camadas de entrada, quinze camadas escondidas e uma camada de saída.	31
Figura 4. Mapa de calor.....	42
Figura 5. Representação em blocos do modelo utilizado para rede neural.	45
Figura 6. Gráfico de dispersão entre a temperatura de escaldagem do 2° tanque de escaldagem e o percentual de absorção.	52
Figura 7. Gráfico de dispersão entre a Temperatura inicial do pré-chiller e o percentual de absorção.....	54

LISTA DE TABELAS

Tabela 1. Composição química (g/100g) e conteúdo energético (Kcal/100g) médio da carne magra, crua e da gordura de alguns animais de abate.	17
Tabela 2. Parâmetros e variáveis.	40
Tabela 3. Parâmetros excluídos.	42
Tabela 4. Configuração com melhor coeficiente de correlação para predição de absorção.	49
Tabela 5. Comparação dos resultados.	50
Tabela 6. Variáveis com maior impacto no percentual de absorção de água em carcaças de frango.	51

LISTA DE QUADROS

Quadro 1. Redes neurais desenvolvidas em frigoríficos.	33
Quadro 2. Parâmetros de abate definidos para análise de correlação com absorção de água em carcaças de frango.....	37
Quadro 3. Parâmetros de abate excluídos e motivo da exclusão.	41

LISTA DE ABREVIATURAS E SIGLAS

DIPOA	Departamento de Inspeção de Produtos de Origem Animal
MAPA	Ministério da Agricultura, Pecuária e Abastecimento
RIISPOA	Regulamento de Inspeção Industrial e Sanitário dos Produtos de Origem Animal
RNA	Rede Neural Artificial
SIF	Serviço de Inspeção Federal

SUMÁRIO

1 INTRODUÇÃO	13
2 OBJETIVOS	15
2.1 Objetivo geral	15
2.2 Objetivos específicos	15
3 REVISÃO BIBLIOGRÁFICA	16
3.1 Mercado e consumo de carne de frango	16
3.2 Propriedades da carne de frango	16
3.3 Etapas do processo de abate de frango	20
3.4 Absorção de água em carcaças de frango	25
3.4.1 Fatores que interferem na absorção	27
3.5 Redes neurais artificiais	28
3.5.2 Redes neurais em abates de frango	32
4 MATERIAL E MÉTODOS	33
4.1 Tipo de pesquisa	35
4.2 Coleta de dados	35
4.2.1 Animais	35
4.2.2 Materiais	35
4.3 Método	36
4.3.1 Percentual de absorção de água pela carcaça	38
4.3.2 Ferramentas utilizadas para desenvolvimento do modelo	39
4.3.3 Google Colab	39
4.3.4 Tratamento dos dados	40
4.3.5 Desenvolvimento da programação	42
4.3.6 Desenvolvimento do modelo	43
4.3.7 Otimização do modelo	45
4.3.8 Avaliação do modelo	46
5. RESULTADOS E DISCUSSÃO	49
6 CONCLUSÃO	55
REFERÊNCIAS	56

1 INTRODUÇÃO

A criação de frangos, ou avicultura, assim como o consumo desta carne vem crescendo cada vez mais. Durante muitos anos, era um processo de produção familiar, onde a maior parte da carne de frango e ovos eram destinadas ao consumo próprio e se comercializava somente o excedente. Contudo, essa área foi se fortalecendo devido aos avanços tecnológicos, melhoramento genético e financiamentos para o setor, por exemplo (Rosseti, 2014). Esses avanços permitiram a expansão do mercado e a popularização da carne de frango na mesa dos consumidores.

A carne de frango é uma proteína muito popular na dieta da população do Brasil, principalmente, devido à facilidade no seu preparo, qualidade nutricional, disponibilidade nos comércios e custo, proporcionando uma nutrição saudável. Em 2020, a proteína de frango foi a carne animal mais consumida em todo o mundo, com um consumo de, aproximadamente, 98 milhões de toneladas, conseguindo superar as carnes bovinas e suínas (Portal do Agronegócio, 2021). Os brasileiros consomem, em média, 43 kg/ano de carne de frango, um número expressivo em comparação a outros países. O país se destaca nesse mercado, estando em terceiro lugar na produção e no consumo, ficando atrás apenas de países como a China e os Estados Unidos (Embrapa, 2022).

Com o aumento da produção da carne de frango nos últimos anos e, conseqüentemente, o seu consumo, o consumidor acabou se tornando mais exigente, sendo que a qualidade da carne se tornou um fator fundamental. O mercado consumidor deseja um produto de padrão elevado, que atenda aos atributos sensoriais de aparência, textura, suculência e sabor. Frente a isso e para garantir a alta qualidade da carne de frango, houve um aumento na fiscalização desses produtos. Entre as preocupações, se destaca a qualidade da carcaça e o excesso de água absorvida durante os processos de abate e resfriamento, os quais podem vir a caracterizar fraude comercial (Silva, 2021).

De acordo com Sant'Anna (2008), o excesso de água não é, necessariamente, resultante da injeção fraudulenta de água no produto, mas do ajuste inadequado de variáveis tecnológicas que influenciam o processo. O sistema que controla a absorção de água junto as carcaças de frangos que são submetidas a um pré-resfriamento pelo

método de imersão, precisa ser eficiente, sem promover prejuízos na qualidade do produto.

Conseguir atender aos limites que são previstos na legislação para o parâmetro de absorção de água promove benefícios, tornando-se relevante para o setor, pois aumenta os lucros do negócio. Contudo, caso se ultrapasse os limites desse parâmetro, ocorre um impacto em retenções das produções, assim como perdas financeiras. Da mesma forma, pode acabar gerando uma imagem negativa da empresa diante dos órgãos responsáveis, como, por exemplo, o Serviço de Inspeção Federal (Martins et al., 2011; Rosa, 2014). Por esses motivos, o tema possui relevância e necessita de mais estudos e pesquisa para garantir a qualidade e evitar problemas durante os processos envolvidos.

De acordo com a Resolução nº 4, a qual foi instituída em 29 de outubro de 2002 do Departamento de Inspeção de Produtos de Origem Animal (Dipoa), do Ministério da Agricultura, Pecuária e Abastecimento (MAPA), o limite máximo considerado para carnes de frango é de 8% de absorção de água, através do método de controle interno, posteriormente a passagem das carcaças pelo pré-resfriamento (*chiller*). Caso ocorra um desvio que ultrapasse esse limite, será considerado fraude. Para o Teste do Gotejamento (*Dripping Test*), o limite estabelecido é de 6% em relação à absorção de água em carcaças de frangos congelados, isso sem considerar os parâmetros que interferem no processo (Brasil, 2002).

Portanto, é necessário sistematizar a analisar o processo como um todo e, conseqüentemente, identificar o efeito de todas as etapas de abate do frango junto a absorção de água nas carcaças das aves. Também é preciso conhecer as tendências, estabelecer parâmetros e ter o controle das variáveis identificadas como maior influenciadora do processo de absorção de água *dripping test* das carcaças de frango (Carciofi; Laurindo, 2007). Para isso, alguns métodos de análise de dados podem contribuir para a qualidade da carne de frango, garantindo que a absorção de água esteja nos níveis adequados.

Neste contexto, esse estudo busca mensurar os impactos de parâmetros conhecidos que podem interferir na absorção de água no processo pós-abate do frango de um frigorífico através da análise de dados em *Python*.

2 OBJETIVOS

2.1 Objetivo geral

Avaliar os fatores de abate que interferem na absorção de água em carcaças de frango utilizando redes neurais artificiais.

2.2 Objetivos específicos

- Coletar dados nas etapas de abate de frango até a etapa de resfriamento das carcaças;
- Correlacionar as variáveis de abate de frango com a absorção de água em carcaças de frango;
- Utilizar redes neurais para avaliar a influência das etapas de abate de frango na absorção de água em carcaças de frango;
- Determinar os parâmetros de processo com maior influência na absorção de água em carcaças de frango.

3 REVISÃO BIBLIOGRÁFICA

3.1 Mercado e consumo de carne de frango

No Brasil, a avicultura de corte, até 1950, era um processo de produção familiar, onde a maior parte da carne de frango eram destinadas ao consumo próprio e se comercializava somente o excedente, na década de 60 começou a se destacar pois seu processo de produção se intensificou devido aos avanços tecnológicos, melhoramento genético e financiamentos para o setor (Rosseti, 2014).

Hoje, o Brasil é um dos maiores produtores de carne de frango do mundo e o principal destino dos produtos é o mercado interno. Segundo dados publicados pela ABPA (2022), das 14,329 milhões de toneladas de frango produzidas em 2021, 67,83% foram voltadas ao mercado interno. Em contrapartida, 32,17% do total de 4,610 milhões de toneladas foram destinadas ao mercado exterior.

A carne de frango por se tratar de um alimento básico, não somente no Brasil, é um dos poucos que não está sujeito, por exemplo, a restrições religiosas. Portanto, está entre as principais fontes de proteína em países que possuem distintos hábitos culturais (ABPA, 2022). Essa aceitação em diversos países faz com que o setor de avicultura, principalmente o da carne, ganhe espaço e se fortaleça economicamente, pois seu consumo cresce em nível mundial.

O consumo de carne de aves (45,3 kg/ano) tem crescido quando comparado ao consumo das carnes bovinas (37,1 kg/ano) e suínas (18 kg/ano), sendo estas três, as que são mais comercializadas em termos mundialmente. No cenário econômico atual, o Brasil tem grande destaque na exportação e produção de carne de frango, produzindo cerca de 15% do total de frangos do planeta. O Brasil, atualmente, é considerado o maior exportador mundial de carne de frango (Brasil, 2022).

3.2 Propriedades da carne de frango

Em relação especificamente à carne de frango, o Departamento de Inspeção de Produtos de Origem Animal (DIPOA) define que a carne precisa ter uma coloração branca, assim como fornecer todos os nutrientes que são necessários em uma dieta equilibrada. Contudo, a quantidade de componentes nutricionais – proteínas, lipídios, vitaminas e minerais – pode variar conforme a raça, a idade do frango, sexo, tipo de

habitat, alimentação fornecida e condições higiênicas onde o animal se encontra (Venturini; Sarcinelli; Silva, 2007).

Assim como os outros tipos de carnes, a de frango também tem propriedades nutricionais relevantes, sendo que ela é considerada uma carne magra. No geral, as carnes do tipo magra são compostas pelos tecidos nervosos, muscular, epitelial e conectivo, esse conjunto possui aproximadamente 70% a 75% do seu peso total em água, contudo irá variar conforme a idade do frango, sendo que nos animais mais jovens a proporção de água no músculo do animal é maior que nos mais velhos. Assim, quanto maior a proporção de gordura, menor será o teor de água (Andrade, 2019).

A água é o principal componente que constitui os fluídos extracelulares, diversos componentes químicos se encontram dissolvidos ou suspensos na água. Basicamente, a carne magra é composta por 21 a 22% de proteínas, a qual constitui a matéria sólida, de 1 a 2% de gorduras, 1% é de minerais e os carboidratos representam menos de 1%. Portanto, o conteúdo energético das carnes magras é relativamente baixo, com cerca de 105kcal/100g por pedaço de carne crua, enquanto nas carnes com mais gorduras, esses valores passam para 830kcal/100gr (Roça, 2008). A composição química e o conteúdo energético dos diferentes tipos de carnes estão representados na Tabela 1.

Tabela 1. Composição química (g/100g) e conteúdo energético (Kcal/100g) médio da carne magra, crua e da gordura de alguns animais de abate.

Carnes	Água	Proteína	Gordura	Minerais	Conteúdo energético
Suína	75,1	22,8	1,2	1,0	112
Bovina	75,0	22,3	1,8	1,2	116
Vitelo	76,4	21,3	0,8	1,2	98
Cervo	75,7	21,4	1,3	1,2	103
Frango – peito	75,0	22,8	0,9	1,2	105
Frango – coxa	74,7	20,6	3,1	-	116
Peru – peito	73,7	24,1	1,0	-	112
Peru – Coxa	74,7	20,5	3,6	-	120
Pato	73,8	18,3	6,0	-	132
Ganso	68,3	22,8	7,1	-	161
Gordura de suíno	7,7	2,9	88,7	0,7	812
Gordura de bovino	4,0	1,5	94,0	0,1	854

Fonte: Adaptado de SEU β, 1991;1993.

Basicamente, a água é o meio de transporte para nutrientes, hormônios, metabólitos e resíduos através do corpo do animal. Sendo que é nesse meio que ocorrem as reações químicas e processos metabólicos. Já na atividade muscular, a água é fundamental, pois ela promove a tanto a pressão e descompressão, como a contração e o relaxamento dos músculos. Portanto, a água possui uma relação direta com as proteínas e esse relacionamento precisa ser contínuo (Roça, 2008).

As proteínas que são componentes musculares são responsáveis por reter a umidade da carne de frango, sendo que isso contribui para o seu rendimento, estrutura, qualidade, aspectos sensoriais e, também, nutricionais. Portanto, a perda da umidade da carne irá comprometer a sua qualidade, fazendo com que o frango tenha uma textura dura, seca e fibrosa e promovendo outras alterações físicas e químicas indesejáveis (Olivo, 2006). As proteínas também são responsáveis pelo funcionamento de reações metabólicas que são vitais para o organismo. Em termos nutricionais, esse componente confere um alto valor biológico, pois possui metionina, treonina e lisina, sendo essa última estritamente essencial (Hautrive; Marques; Kubota, 2012).

As proteínas constituintes das fibras musculares podem ser classificadas em: vermelhas, intermediárias e brancas. A diferença entre elas se encontra na resposta da sua relação com a contração muscular, pois quanto mais claras, mais rápida é a contração e quanto mais escura, mais lenta e tônica é essa contração (Braccini et al., 2021). Ainda se encontram as proteínas miofibrilares, sarcoplasmáticas e as insolúveis.

Proteínas miofibrilares compõem de 65% a 75% de toda a musculatura, sendo que a actina corresponde de 20% a 25% das proteínas miofibrilares e a miosina de 50% a 55%, sendo que possuem maior importância no período após o abate. As proteínas sarcoplasmáticas são aquelas solúveis em água e são representadas pela mioglobina, enzimas e hemoglobina. Já as insolúveis são aquelas que possuem a função de recobrir as fibras e feixes musculares, sendo compostas pelo colágeno, elastina e reticulina (Ordonéz et al., 2005). As proteínas miofibrilares têm um enorme valor biológico, pois possui todos os aminoácidos essenciais que são necessários para a dieta do ser humano, sendo fundamentais para o desenvolvimento celular (Valsechi, 2001). Além disso, quando não há a presença de carboidratos e gorduras, as proteínas suprem as necessidades energéticas do ser humano, apesar de ser com um rendimento menor.

Além das proteínas, a carne de frango é uma fonte de energia, devido a presença dos lipídios, assim como conferem propriedades sensoriais de textura, cor, aroma e sabor (Valsta, 2005). A quantidade de gordura também será influenciada pela raça, idade, sexo, tipo de alimentação, tipo de corte, entre outros, sendo que essa carne possui menos lipídios saturados quando comparada a carne de suínos e bovinos (Gomide et al., 2013). Entre os tipos de lipídios, ocorre a predominância dos ácidos graxos e glicerídeos, os quais são considerados lipídios neutros. Entre suas funções está a contribuição para a estrutura e funcionamento adequado da membrana celular, ou seja, possui função metabólica. Entre os tipos de cortes, o peito do frango possui baixo teor de gordura, principalmente devido a sua região anatômica, a qual não precisa de uma quantidade grande de reserva de energia, ou seja, reserva de gordura. Já na cavidade abdominal e nas sobrecoxas, há a maior presença de gorduras, pois além dessa região precisar de reserva energética, também atua como isolante térmico e possibilita maior duração das atividades físicas (Marx, 2014).

Já em relação aos carboidratos, a carne de frango é considerada pobre nesses componentes, sendo constituída de glicogênio (polissacarídeos), assim como glicose e frutose (monossacarídeos). A quantidade de glicogênio presente irá depender do tipo de musculatura e da atividade do animal. Em animais vivos, se encontra em torno de 1,5% glicogênio, já após o abate, fica em torno de 0,1%. Diferente da musculatura, as vísceras comestíveis são muito ricas em carboidratos, sendo que o fígado possui de 2% a 4% desses componentes. Quando a carne de frango é assada, os carboidratos vão se combinar com os aminoácidos livres, formando, conseqüentemente, as melanoidinas, as quais promovem o sabor e odor característico desse tipo de carne (Roça, 2008).

Com relação as vitaminas, a carne de frango apresentam todas as lipossolúveis (A, D, E e K), assim como as hidrossolúveis do complexo B, como a tiamina, nicotinamida, ácido fólico, entre outras. Também tem a ocorrência de vitamina C, mas essa é em pouca quantidade (Ordóñez, 2005). Dentre todas essas vitaminas, a principal é a vitamina A, sendo que dos alimentos de origem animal, o frango é o único que fornece esse tipo de componente. Também é importante ressaltar que é uma fonte de vitaminas do complexo B, sendo essa fundamental para o crescimento e manutenção do corpo humano (Araújo, 1995). A idade do animal é um fator determinante para os níveis de vitaminas, sendo que animais jovens possuem

menores níveis de B12, enquanto os mais velhos possuem maiores níveis de vitaminas lipossolúveis (Embrapa, 2017).

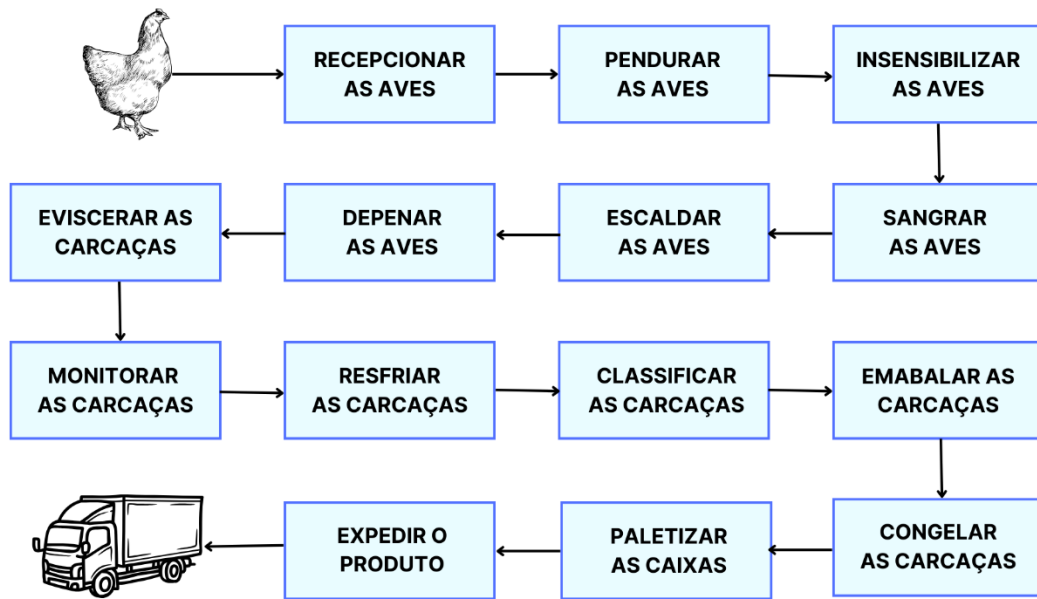
A respeito dos minerais, a carne de frango possui ferro, potássio, sódio, fósforo, zinco e magnésio. A carne de frango é considerada muito expressiva em relação a quantidade de ferro, sendo que de 40% a 60% desse componente é altamente absorvível. Devido a união de todos esses componentes, proteínas, vitaminas e minerais, assim como a baixa quantidade de lipídios, essa carne é muito relevante em uma dieta balanceada e atende a todas as exigências nutricionais em crianças, adolescentes, adultos e jovens (Luchiari Filho, 2000).

Portanto, a carne de frango é fundamental para o ser humano, pois fornece diversos benefícios nutricionais, além de ter pouca gordura. Devido a crescente procura dos consumidores por essa carne, houve uma preocupação maior das indústrias pela qualidade e valor nutricional agregado ao frango, sendo que a absorção de água durante o processo de abate se tornou alvo de preocupação.

3.3 Etapas do processo de abate de frango

O processo de abate de frango é dividido em distintas etapas, visando a sua comercialização e o consumo. Por se tratar de uma matéria-prima viva, é preciso que haja uma técnica receptiva para o abate do animal, tornando possível a manipulação da carne durante todo o processo de abate. No Brasil, é necessário seguir diretrizes que são estabelecidas pelo Regulamento de Inspeção Industrial e Sanitário dos Produtos de Origem Animal (RIISPOA), conforme a portaria 210, promulgada em novembro de 1998 (Brasil, 1998), onde foram padronizadas todas as etapas, as quais podem ser divididas em cortes ou embalagem individual, estão exemplificados na Figura 1.

Figura 1. Fluxograma padrão de abatedouro de frango



Fonte: Adaptado de Brasil, 1997.

A Figura 1 demonstra as etapas dentro de um abatedouro de frango, desde o seu recebimento, processo insensibilização das aves, momento do abate, escaldagem, depenagem, evisceração, resfriamento, classificação, embalagem das aves, congelamento, armazenagem em paletes e expedição do produto para comercialização (Embrapa, 2017).

Por se tratar de uma matéria-prima viva, ou seja, propensa a contaminantes, os cuidados precisam ocorrer desde a etapa do pré-abate dos frangos. Nesta etapa, os frangos, que estão com a idade considerada ideal para o abate, são transportados para o complexo fabril, sendo que essa fase pode ser dividida em quatro operações: a programação de retirada; tempo de jejum; carregamento; e transporte. Essa é uma das principais etapas quando se trata da qualidade e rendimento da carne, pois qualquer alteração nesta pode ser prejudicial para o produto final. Logo, essa etapa precisa ser bem planejada, assegurando a integridade das aves, atendendo, desta forma, as normas de bem-estar animal (Mendes, 2001).

Ludtke, Vilela e Costa (2009), citaram que os problemas de bem-estar relacionados ao transporte e a descarga das aves são a morte, hematomas, fraturas, lesão de pele, exaustão metabólica, desidratação e estresse térmico. Estes problemas podem interferir de forma direta na qualidade da carcaça, rendimento e, conseqüentemente, modificando os custos de produção.

Dentro da indústria, o processo começa com a recepção de aves na plataforma, onde é realizada a pesagem do caminhão juntamente com os animais. Neste momento, é definido o peso médio das aves e, após a pesagem, os animais são destinados para uma área, normalmente chamada de galpão de descanso ou espera, onde será realizada a conferência dos documentos (Brasil, 1998). O momento de descanso da ave é importante para a qualidade da carne, pois reduz o estresse do animal e o calor, os quais estão relacionados a reações químicas que podem interferir nas características da carne. O alto nível de estresse pode provocar uma diminuição no tempo de *rigor mortis*, ou seja, a transformação do músculo em carne, fazendo com que a carne fique mais dura (Mendes, 2001).

Após a fase de descanso e inspeção no galpão, o caminhão se direciona para a plataforma onde se iniciará a etapa de pendurar aves. A pendura é realizada através do enganchamento das aves pelos pés, de maneira manual, iniciando, assim, o processo de abate na linha de produção. A sala de pendura é um ambiente climatizado e de luz azul, visando evitar o estresse da ave e o batimento das asas durante o percurso até a sangria, o que pode causar fraturas e hematomas (MAPA, 2021).

Após a pendura, essas aves são insensibilizadas por eletro narcose, pelo método de imersão em água, onde elas passam pela cuba de choque com a água que atinge a altura do peito. Nesse momento, os animais recebem uma descarga elétrica que é suficiente para causar o atordoamento. Esse tipo de método é muito comum para abates humanitários de aves, pois quando a corrente elétrica passa pelo cérebro, causa despolarização dos neurônios, impedindo a passagem de estímulos, tornando os animais inconscientes e insensíveis à dor. Em seguida, as aves são sangradas imediatamente após a insensibilização, por meio de um corte no pescoço realizado por pessoas treinadas (Ludtke et al., 2010).

O percurso entre a sangria e a escaldagem deve ser realizado em um período de no máximo 3 minutos, pois, após esse tempo existirá interferência na qualidade da depenagem (Tavernar; Albino; Araújo, 2012). A escaldagem é um processo que consiste em afrouxar e amaciar as penas das carcaças através de um tanque de água com temperatura em média de 52°C. Essa etapa deve ser ajustada de acordo com a ave a ser abatida, levando em consideração os aspectos higiênicos e os cuidados para escalda excessiva, evitando a ocorrência de queimaduras no peito e coxas (Matsumura, 2007). Após essa etapa, se inicia a depenagem, etapa mecanizada, onde os equipamentos são constituídos por um rolo que possui dedos de borracha, sendo

que, normalmente, após esse procedimento, é necessário realizar a revisão e retirada manual das penas que ficaram na carcaça pelos funcionários do SIF (Serviço de Inspeção Federal) (Venturini; Sarcinelli; Silva, 2007).

Na etapa de eviscerar o frango, ocorre a lavagem prévia, retirada da cloaca, seguida da abertura de abdômen para extração de suas vísceras. As vísceras são examinadas e separadas, o pulmão é retirado por meio de pistola a vácuo. Após esses procedimentos, a carcaça é lavada em chuveiro de aspensão e direcionada para o resfriamento (Tavernar; Albino; Araújo, 2012).

A etapa de resfriamento corresponde ao processo de refrigeração e manutenção da temperatura entre 0°C e 4°C dos produtos de aves, havendo uma tolerância de 1°C medidos internamente (Brasil, 1998). O resfriamento é realizado por dois equipamentos, o *pré-chiller* e o *chiller*, cada um com sua particularidade. O *pré-chiller*, responsável pelo pré-resfriamento, é o primeiro tanque que, além de resfriar, tem a função de limpar e reidratar a carcaça de frango, sendo o primeiro tanque. Nele, a temperatura da água não pode ser superior a 16° C e o tempo de imersão varia de 10 min a 30 min, pois depende do tamanho da ave, da qualidade desejada e da distância do mercado (Mastrogiacomo, 2006). Durante todos os processos anteriores, a carcaça vai sendo desidratada, por isso, o *pré-chiller* é fundamental para recuperar a água perdida durante os processos anteriores, garantindo a conservação e a boa apresentação do produto. Essa recuperação ocorre devido à penetração da água na pele, na fásia e em outros tecidos subcutâneos.

Após a etapa de pré-resfriamento, as carcaças apresentaram, em média, uma temperatura de 25°C. Esta faixa de temperatura, nos primeiros momentos *post mortem*, é de extrema importância, pois o resfriamento não pode ocorrer de maneira brusca. Caso ocorra um resfriamento rápido, em baixas temperaturas, pode acontecer o encurtamento das fibras musculares ocasionadas pelo frio, levando a redução da maciez da carne (Bressan; Beraquet, 2004).

O *chiller* é o tanque de resfriamento principal, sendo que o equipamento se comporta de maneira semelhante ao *pré-chiller*, mas possui extensão de comprimento e tempo de retenção maior. As carcaças ficaram, em média, de 45 a 60 min no *chiller*, onde o equipamento opera com temperaturas menores que 4°C, eliminando o calor *post mortem* e garantindo a segurança, pois diminui a atividade microbológica presente na carcaça. No final desta etapa, as carcaças devem apresentar a temperatura interna, medida no centro do peito, de até 7°C (Cotta, 2017).

Ainda considerando a etapa de pré-resfriamento e resfriamento de carcaças de frango, existem dois métodos mundialmente conhecidos. O método de imersão de carcaças em tanques contínuos com água gelada, sendo esses tanques conhecidos como *chiller*, e o método de passagem em câmara com ventilação de ar forçado e gelado, conhecido como *air chiller* (Mastrogiacomo, 2006). De acordo com Fluckey et al. (2003), o sistema de imersão em água é o mais utilizado no mundo devido sua eficiência. Nesse sistema, as carcaças de frango podem absorver de 4% a 6% de água através da pele e tecido adiposo circundante. Nesse tipo de resfriamento, não há nenhuma absorção de umidade, resultando em um rendimento negativo, pois ocorre uma perda excessiva de umidade (James et al., 2006; Carcinof; Laurindo, 2007). De acordo com a portaria nº210 (Brasil, 1998), a quantidade de água absorvida depois da etapa de pré-resfriamento não pode superar o limite máximo de 8% do seu peso. Já a temperatura das carcaças precisa se manter igual ou inferior a 7°C no interior das massas musculares, mas é aceita uma temperatura de 10°C para as carcaças que passarão pelo congelamento imediatamente.

Após serem retiradas do *chiller*, as carcaças são rependuradas nos ganchos, nesse momento, deve-se realizar o gotejamento com o objetivo de retirar o excesso de água englobada durante a etapa de pré-resfriamento. Nesta etapa, deve haver o monitoramento interno, sendo realizado imediatamente após o resfriamento da carcaça por imersão. Esse período é compreendido entre todo o tempo de imersão em *pré chiller* e *chiller*, adicionado ao tempo de gotejamento. O seu índice de absorção é indicado em porcentagem de umidade em relação ao peso inicial, medido imediatamente antes do início do resfriamento, sendo que esse valor tem limite máximo de 8% (Santos, 2012).

Após a etapa de resfriamento, as carcaças de frango são embaladas e destinadas ao congelamento, onde a temperatura do túnel deve ser de -35°C a -40°C por 4 horas. Considerando o armazenamento, que deve ser realizado sob uma temperatura de até -12°C, o produto pode ter uma durabilidade de 8 a 18 meses. Por fim, o produto segue para expedição e destinado aos mercados consumidores (Santos, 2012).

3.4 Absorção de água em carcaças de frango

O termo carcaça pode ser definido como o corpo inteiro de um frango após passar pelo processo de insensibilização ou não, etapa de sangria, depenagem e retirada das vísceras. Nesse processo, são excluídos o papo, traqueia, esôfago, intestinos, cloaca, baços e órgãos reprodutores e pulmões. No entanto, a retirada dos rins, pescoço, pés e cabeça é uma opção facultativa (Brasil, 1998). Dentro da indústria de abate e processamento de carcaças de aves, uma das mais importantes, se não a mais importante operação unitária é a etapa de resfriamento de carcaça ou pré-resfriamento. É nesta etapa que a ave é submetida a uma redução drástica de temperatura, cerca de 35°C, a qual é medida no centro do músculo peitoral (Carciofi, 2005). Ainda, para garantir a preservação da qualidade das carcaças, um processo de resfriamento adequado é fundamental.

De acordo com Mastrogiacomo (2006), reduzir a temperatura *post mortem* é um fator crítico, pois interfere na obtenção da qualidade da carne, sendo assim, se torna necessário iniciar o processo de redução de temperatura o mais breve possível após o sacrifício da ave. Esse procedimento sucede um ritmo cadenciado das reações bioquímicas *post mortem*, evitando a rápida queda do pH muscular e a ação de forma descontrolada de enzimas naturais proteolíticas. Desta forma, ocorre a inibição e o retardamento das reações físico-químicas indesejadas, as quais podem proporcionar alterações degradativas da carne, entre elas, a desnaturação proteica e a rancificação oxidativa. A eventual desnaturação proteica, devido ao rápido abaixamento do pH muscular, afeta propriedades funcionais da carne, sucedendo um produto final ou uma matéria-prima de qualidade inferior. Outro fator a ser considerado, com a rápida redução da temperatura da carcaça, é a inibição do desenvolvimento microbiológico, garantindo maior extensão de vida útil do produto e maior segurança para os consumidores. Ainda há o fator de absorção de água nas carcaças, o qual também pode interferir na integridade e qualidade do produto.

O índice de absorção é o percentual de água que é adquirida pelas carcaças de frango ao longo do processo de abate, assim como nas outras operações tecnológicas. Isso ocorre, especialmente, no sistema de pré-resfriamento por imersão, pois uma pequena absorção percentual de água ocorre ao longo das etapas de escaldagem, depenagem e distintas lavagens durante a evisceração (Carciofi, 2005). É na etapa de pré-resfriamento que ocorre o maior índice de absorção de água em

carcaças, o nível de absorção vai depender do tempo de residência da carcaça e, também, da temperatura do tanque de pré-resfriamento (Mastrogiacomo, 2006).

De acordo com o regulamento instituído pelo Ministério da Agricultura e do Abastecimento, o limite máximo de absorção é de 8% do peso da carcaça (Brasil, 1998). Esse regulamento começou a ser instituído pela Lei nº1.283, de 18 de dezembro de 1950, e pela Lei nº7.889, de 23 de novembro de 1989. Em 2010, iniciou o Programa de Combate à Fraude por Adição de Água em Carcaças de Aves, previsto pela Instrução Normativa nº32, cujo propósito consiste em coibir a fraude que pode ocorrer durante o processo de resfriamento das carcaças de aves. Esse programa tem como base fundamentos previstos pela Portaria nº210, de 10 de novembro de 1998, que aprovou o Regulamento Técnico de Inspeção Tecnológica e Higiênico-Sanitária de Carnes de Aves. Esse regulamento técnico estabelece a metodologia de análise (*dripping test*) e determina o limite máximo de 6% de água resultante do descongelamento das carcaças congeladas (Brasil, 1998). A partir de 2005, as empresas passaram a desenvolver o Programa de Prevenção e Controle de Adição de Água aos Produtos, onde devem estar descritos os controles executados, com o objetivo de evitar e prevenir possíveis fraudes econômicas provenientes dos diferentes processos produtivos na indústria de aves e derivados. Especialmente, aqueles relacionados ao aumento na concentração de água e salmoura agregada às carcaças, cortes e produtos de carne de aves (Brasil, 1998). Caso sejam constatadas concentrações de água acima do permitido pela legislação vigente, que é de 6%, aplica-se medidas administrativas previstas pela Resolução nº4, de 29 de outubro de 2002.

O método de análise de gotejamento ou *drip test* é uma das formas de controlar os limites de absorção em carcaças de frango, sendo que essa técnica tem como objetivo medir a quantidade de água obtida através do descongelamento da carcaça. Se a quantidade resultante, a qual é expressa em porcentagem de peso da carcaça, acabar sendo superior a 6% do limite estabelecido pela portaria nº210 (Brasil, 1998), considera-se que a carcaça está com excesso de água, ou seja, alguma fraude pode ter ocorrido no processo de pré-resfriamento (Mastrogiacomo, 2006). De acordo com Sams (2001), frequentemente ocorre variações na perda de umidade (*drip lost*) durante a comercialização, com valores acima do aceitável, mesmo quando a absorção ocorreu dentro dos níveis legais. Este fenômeno pode acontecer devido às variações de temperatura de armazenamento, resultando em situações de

desconforme devido ao prejuízo financeiro. Neste sentido, a temperatura de armazenamento é considerada um fator crítico para o *dripping test*.

3.4.1 Fatores que interferem na absorção

A porcentagem de água que é absorvida pela carcaça ao longo da etapa de pré-resfriamento é considerado um dos ganhos mais relevantes em relação a qualidade final do produto, ao rendimento da carcaça, assim como pela lucratividade. O controle de algumas variáveis é necessário para garantir que todo esse processo seja feito de modo eficiente e satisfatório. Entre as variáveis a serem consideradas, estão: temperatura da água dentro dos resfriadores, sistema de injeção de ar (ou borbulho) e qual o tempo de retenção das carcaças no sistema. Algumas variáveis são menos influentes, mas também precisam ser consideradas, como: velocidade ao longo da linha de abate, o tempo de jejum que a ave se encontra, o total de matéria orgânica que está presente na água do sistema de imersão, sexo, a linhagem das aves, sua idade, entre outros (Oliveira, 2016).

As etapas iniciais são de extrema importância para o produto final, pois o manejo dos animais incorreto pode acarretar diversos problemas relacionados a qualidade da carne. O estresse dos animais nas fases iniciais do processo é um dos principais fatores negativos na absorção de água em carcaças de frango, pois altera aspectos importantes na homeostase do organismo da ave. Nesse sentido temos o estresse, o qual é um conjunto de fatores ou reações do organismo perante as agressões que podem ser de ordem psíquica, física, entre outras, sendo um dos principais responsáveis por perturbar a homeostase. Dependendo do grau de estresse, alguns defeitos aparecem após a morte do animal, pois ocorrerá a ausência contínua de oxigênio e a falta de corrente sanguínea, fazendo com que aumente a concentração de ácido lático, diminuindo o pH, levando a fadiga e injúria muscular. Esse processo vai acabar interferindo na transformação do músculo em carne e, conseqüentemente, na sua qualidade (Brossi et al., 2009; Gherardi, 2013; Monteiro et al., 2017).

Outro fator crítico a ser observado é o pH, pois dependendo da velocidade de decaimento na fase de *rigor mortis* e da temperatura da carcaça, pode ocorrer a desnaturação das proteínas, comprometendo a qualidade da carne. Neste caso, a carne ficará pálida e com baixa capacidade de reter a sua própria umidade, causando

o fenômeno conhecido como PSE (*Pale, Soft, Exudative*). A desnaturação proteica é um dos problemas causados pelo estresse da ave, ela é a perda da estrutura tridimensional da proteína, onde ocorre interferência nas interações fracas, principalmente as pontes de hidrogênio, perdendo sua funcionalidade, como a solubilidade e a capacidade de ligar e reter água. Desta forma, pode interferir na absorção de água das carcaças de frango (Guarnieri, 2003; Brossi et al., 2009; Monteiro et al., 2017).

3.5 Redes Neurais Artificiais (RNA)

A fim de analisar quais são os principais fatores que acabam interferindo na absorção de água em carcaças de frango, esse trabalho irá utilizar os conceitos de redes neurais. Essa ferramenta tem como propósito simular a inteligência humana e resolver problemas que possuem mais de uma variável (Silva, 2021).

Uma das áreas de pesquisa mais interessante e almejada no meio da tecnologia é a simulação da inteligência humana por meios tecnológicos. A ciência projeta máquinas capazes de se assemelhar ao comportamento humano, cujo principal objetivo é de replicar as reações humanas. Sabe-se que a inteligência humana é a mais avançada dentre os seres existentes no planeta terra e o local dessa inteligência é o cérebro. Para a realização de pensamentos, os neurônios são componentes fundamentais, se conectando através de uma rede, permitindo a troca de informações e criando a inteligência biológica. Como dito anteriormente, a ciência tenta replicar a estrutura e o funcionamento dessa fonte de inteligência através de máquinas. Logo, isso significa que a pesquisa tenta entender o funcionamento da inteligência residente nos neurônios e mapeá-la para uma estrutura artificial, por exemplo, uma combinação de *hardware* e *software*, transformando as redes neurais biológicas em redes neurais artificiais (Raubert, 2014).

Comparando o modelo artificial de redes neurais com o modelo biológico, sabe-se que, obviamente, a ciência ainda não conseguiu atingir o objetivo de replicar a inteligência humana totalmente em máquina, o fato é que modelo artificial tem muito pouco em comum com o modelo biológico. Entretanto, existe um paralelo entre às duas vertentes que prometem que as redes neurais artificiais sejam uma aproximação apropriada para resolver problemas cognitivos complexos (Raubert, 2014). O uso de

redes neurais artificiais é um tema consolidado como alternativa a computação tradicional programada para resolução de problemas que possuem muitas variáveis impactantes e demandam uma análise mais complexa (McCulloch; Pitts, 1943).

A história das redes neurais de inicia em 1943, onde dois pesquisadores, McCulloch e Pitts, publicaram o primeiro registro de redes neurais. Essa área inovadora da computação tinha como base o funcionamento dos neurônios biológicos, para isso eles modelaram uma rede neural simples utilizando circuitos elétricos. No ano de 1949, o pesquisador Hebb, apresentou o primeiro método de treinamento para RNA's. Neste sentido, ele descobriu que os caminhos neurais são fortalecidos, cada vez mais que usamos, um conceito fundamental para a maneira que os humanos aprendem. Conforme os computadores foram avançando em suas tecnologias, durante a década de 1950, foi possível realizar uma simulação hipotética de uma rede neural. Quem deu o primeiro passo nesse sentido foi Nathaniel Rochester, pertencente aos laboratórios de pesquisa da IBM. Contudo, a sua primeira tentativa acabou falhando. Em 1957, Frank Rosenblat desenvolveu o primeiro neurocomputador, logo em seguida, nos anos de 1958 a 1962, foi elaborada uma classe de RNA's denominada como *Perceptrons* (Silva et al., 2010).

A partir da década de 1980, as pesquisas sobre as redes neurais passaram por uma revolução. Essa área vem se destacando até hoje, pelas características promissoras dos modelos propostos e condições de implementação, as quais possibilitam o desenvolvimento de arquiteturas neurais paralelas em *hardware*. Desta forma, consegue-se obter ótimas performances, muito superiores aos sistemas convencionais. Nesse sentido, têm-se as redes neurais profundas, ou também chamado de *Deep Learning* (Data Science Academy, 2022).

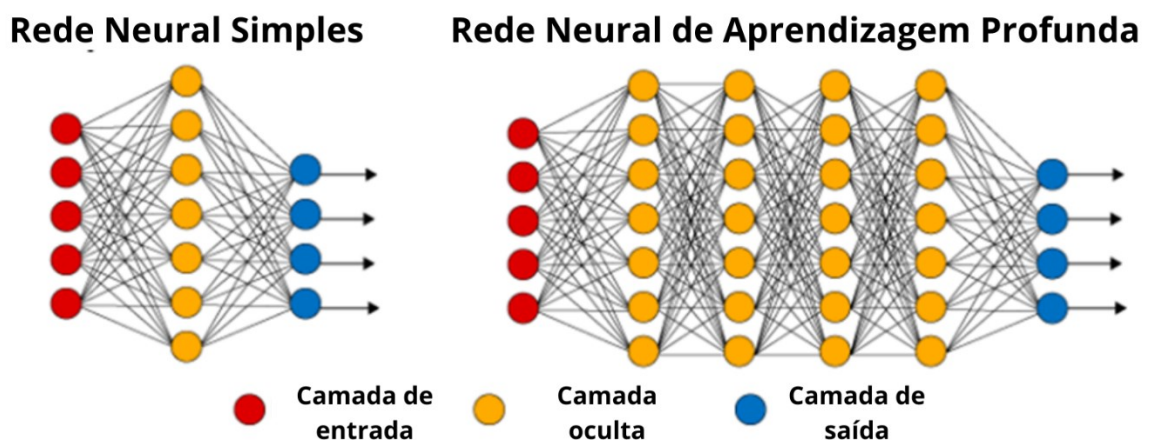
O uso da inteligência artificial se baseia na formulação de hipóteses e confirmações experimentais, aplicando cálculos matemáticos. Sob o ponto de vista empírico, o RNA destina-se a pensar como os seres humanos, permitindo o aprendizado com experiências. Nessa ótica, os RNA's consistem em métodos chamados de *deep learning*, os quais tem capacidade de reconhecer padrões numerosos ou complexos, onde o aprendizado acontece dentro da própria rede. Os RNA's são representados na forma de neurônios humanos e visam replicar o aprendizado através da criação de sistemas que permitem o aprendizado por meio de exemplos de treinamento (Alves, 2020).

Essas redes profundas utilizam camadas de neurônios matemáticos para o processamento de dados, buscando a compreensão da fala humana e o reconhecimento visual de objetos. Nesses sistemas, a informação consegue passar por cada camada, onde uma camada de saída anterior promove a entrada para a camada seguinte. A entrada corresponde a primeira camada da rede, já a de saída é representada pela última camada. Todas as camadas que se encontram entre essas duas, entrada e saída, são chamadas de ocultas. Cada uma delas é formada por um algoritmo simples, que contém um tipo de função para sua ativação (Data Science Academy, 2022).

Existem diversas arquiteturas para as redes neurais artificiais, entretanto, nem todas são *deep learning*. O modelo *Perceptron* é considerado o mais simples, apesar disso, ele permite uma compreensão clara de como funciona uma rede neural em termos matemáticos. Basicamente, ele recebe várias entradas de dados e produz uma única saída. Sendo assim, é ideal para tomar decisões ou comprovar evidências simples, mas não é ideal para decisões humanas.

Para o método *deep learning* utiliza-se a rede MLP (*Multilayer Perceptron*) ou PMC (*Perceptron Multicamadas* – Figura 2), que é um tipo de rede neural artificial retroalimentada, a qual gera uma série de saídas a partir de um conjunto de entradas. Neste caso, se diferencia da rede *Perceptron*, que é uma rede comum que tem como finalidade ter, apenas, uma saída (Marsland, 2014).

Figura 2. Rede Neural Simples e Rede Neural Profunda (Deep Learning).




Fonte: Data Science Academy (2022).

Pode-se observar na Figura 2 como é a esquematização da rede *Perceptron* multicamadas, onde essa é constituída de diversas camadas em grafos, de forma que o sinal parte para um único sentido e cada nó tem uma função de ativação não linear, ou seja, é uma rede neural artificialmente composta por mais de um *Perceptron*. Os nós mencionados são as unidades fundamentais para as redes neurais artificiais, sendo conhecido por neurônio matemático, o qual se baseia no neurônio biológico.

Nesta rede existe uma camada de entrada de nós de fonte e uma camada de saída de neurônios. A camada de entrada tem como função receber todos os estímulos externos e, após, enviá-los ao restante da rede, deixando de fazer o processamento da informação. Assim, a informação é processada na camada de saída, de maneira que o fluxo de informação é dado somente em um sentido. A camada de saída não influencia os nós de entrada e os neurônios de uma mesma camada não estão relacionados entre si (Vieira, 2007). Já os MLP's (Figura 3) são aplicados a problemas de aprendizagem supervisionados. Eles realizam o treinamento de um conjunto de pares entrada-saída e aprendem a modelar a correlação formada entre as entradas e saídas. O treinamento compreende o acerto dos parâmetros, ou os pesos e *bias*, do modelo a fim de reduzir o erro encontrado (Silva,2020).

Figura 3. Estrutura de neurônios da MLP com N camadas de entrada, quinze camadas escondidas e uma camada de saída.



Fonte: Verissimo et al. (2020).

Em 1991, por Guido van Rossum, foi criada a Linguagem de Programação *Python*, focada em produtividade e legibilidade, com o objetivo de produzir um código fácil para o programador entender, possuindo aspectos como: baixo uso de caracteres especiais; baixo índice de palavras-chave; e gerenciador de memória eficiente que evita vazamento de memória (Borges, 2014). Também possui uma biblioteca padrão muito extensa, de tal forma a ter uma diversidade de abordagens prontas para serem utilizadas, seja acesso a banco de dados, trabalho com números complexos, interfaces gráficas ou outras ferramentas estatísticas.

O *Python* também é multiplataforma, e caso apareça alguma que ainda ele não suporte, os desenvolvedores podem modificar o código para que seja possível compilar para aquela linguagem, pois o *Python* também é uma linguagem livre. Todos esses fatores fazem com que o *Python* seja uma das linguagens preferidas para o trabalho com inteligência artificial, *data mining* e *machine learning*.

3.5.2 Redes neurais em abates de frango

O uso de redes neurais já vem sendo estudado para analisar a criação e o abate de frangos. O trabalho de Silva (2021) teve como objetivo realizar uma avaliação, através de redes neurais, dos impactos dos fatores pré-abate que possuem influência na absorção de água de carcaças de frango. Entre os fatores que obtiveram maior impacto está a temperatura do ambiente interno e externo, coeficiente de absorção, tempo de espera dentro do galpão e a distância do transporte. O autor concluiu que o estresse térmico sofrido pelas aves acaba influenciando diretamente na absorção de água nas carcaças.

Já Klassen et al. (2009) investigou várias estruturas de redes neurais com uma camada intermediária a fim de modelar o processo de resfriamento de frangos. Os achados demonstram que até o RNA mais simples conseguiu ajustar, de forma adequada, os dados experimentais e que a rede com 8 neurônios na camada de entrada e 24 na intermediária foram as que melhor representaram o sistema em questão. Portanto, o autor concluiu que as redes neurais são ferramentas eficientes para modelagem de sistemas.

Reali (2004) tentou explicar os fenômenos que ocorrem durante a criação de aves de corte por meio de redes neurais, utilizando uma série histórica de 2001 a 2002. O autor ressalta que o uso de redes neurais conseguiu explicar tais fenômenos,

mostrando-se uma ferramenta útil e objetiva. Leal (2021) utilizou as RNA's para definir parâmetros dentro do processo produtivo que influenciam no *drip test* e absorção de carcaças de frango, para isso realizou mais de 1086 testes formando cerca de 480 estruturas diferentes de redes neurais para a fase de definição do método e 606 na etapa de otimização dos melhores resultados, através dessas análises concluiu que os principais fatores são peso médio, tempo de retenção no *pré-chiller*, temperatura do *pré-chiller* e temperatura dos tanques de escaldagem. Leal (2021) ressalta que com a otimização dos resultados foi possível comprovar que esses fatores impactam diretamente no processo, e devem ser controlados de forma contínua, a fim de minimizar os desvios previstos na legislação.

Quadro 1. Redes neurais desenvolvidas em frigoríficos.

Autor	Ano	Descrição	Resultados
Silva	2021	Realizou uma avaliação dos impactos dos fatores pré-abates na absorção e no <i>dripping test</i> .	Temperatura do ambiente interno e externo, coeficiente de absorção, tempo de espera dentro do galpão e a distância do transporte.
Klassen	2009	Investigou várias estruturas de redes neurais com uma camada intermediária, a fim de modelar o processo de resfriamento de frangos.	Rede com 8 neurônios na camada de entrada e 24 na intermediária foram as que melhor representaram o sistema em questão.
Leal	2021	Utilizou as RNA's para definir parâmetros dentro do processo produtivo que influenciam no <i>drip test</i> e absorção de carcaças de frango.	Principais fatores são peso médio, tempo de retenção no <i>pré-chiller</i> , temperatura do <i>pré-chiller</i> e temperatura dos tanques de escaldagens.

Fonte: Autoria Própria (2023).

Portanto, as contribuições científicas das redes neurais artificiais destacam-se na capacidade de modelar e compreender complexos processos, como os envolvidos na produção avícola conforme sintetizado no Quadro 1. A pesquisa de Klassen et al. (2009) evidenciou que até mesmo redes neurais simples são eficazes em ajustar dados experimentais, demonstrando a versatilidade dessas ferramentas na modelagem de sistemas dinâmicos. A abordagem de Silva (2021) para avaliar os impactos dos fatores pré-abate na absorção de água ressalta a capacidade das redes neurais em lidar com múltiplas variáveis interdependentes. Além disso, Leal (2021) demonstrou que o uso de redes neurais não apenas identifica fatores críticos, mas também otimiza resultados, contribuindo para uma compreensão mais profunda dos processos produtivos. Esses estudos coletivamente sublinham que as redes neurais

são instrumentos eficientes e objetivos, proporcionando avanços significativos na modelagem e análise de sistemas complexos, como os encontrados na produção avícola.

4 MATERIAL E MÉTODOS

4.1 Tipo de pesquisa

O experimento proposto foi desenvolvido na modalidade de pesquisa exploratória e estudo de caso, utilizando análises quantitativas e aplicando em análise multivariada através do software *Phyton*.

4.2 Coleta de dados

4.2.1 Animais

Para análise de dados, foram coletadas 118 carcaças de frangos de um processo industrial, com idade média de 28 dias, peso médio de 1,350 kg, linhagens ROSS e COBB, lotes de fêmeas e machos. Esses fatores já são definidos devido ao tipo do abate padronizado na indústria onde foram realizadas as coletas. O estudo proposto foi realizado em uma indústria frigorífica de grande porte localizada no município de Francisco Beltrão – PR.

4.2.2 Materiais

De acordo com o protocolo já estabelecido pela empresa, foram utilizadas fitas de coloração verde para identificação das carcaças, sendo colocados na etapa de evisceração das aves. Foi utilizada uma balança digital com precisão de 1 grama para determinar a quantidade de água absorvida pela carcaça durante o processo de resfriamento, termômetros, bacias brancas para depósito das amostras, cronômetros, caneta, carrinho de transporte, luvas nitrílicas, prancheta e planilhas em papel para preenchimento de dados obtidos.

4.3 Método

Foram avaliadas 118 carcaças de frango no período de dezembro de 2022 até novembro de 2023, para garantir a assertividade dos dados, observando, desde o início do processo, as variáveis que podem afetar a absorção de água nessas amostras. Dentro do abatedouro, foram coletadas informações a partir da área de recepção das aves até a saída do resfriamento.

Nas etapas de recepção e pendura de aves foram registrados os seguintes parâmetros: lote, carga, sexo, raça e peso médio. Seguindo nas etapas de escaldagem e depenagem de aves, foram avaliados os parâmetros de temperatura dos tanques de escaldagem, peito queimado, velocidade da linha, tempo de imersão nos tanques de escaldagem e temperatura da água das depenadeiras.

No resfriamento, as carcaças marcadas com o lacre foram pesadas antes de entrarem no *pré-chiller* e após a saída do *chiller*, para o cálculo do percentual da absorção, verificando, assim, o rendimento daquela carcaça. Essas carcaças foram pesadas em balança digital e para o cálculo da absorção foi feita a diferença entre a massa final e a massa inicial dividido pela massa inicial conforme equação 1. Esses valores foram colocados em planilha. Outros parâmetros também foram avaliados nessa etapa, como as variações de temperatura, tempo de imersão no *pré-chiller* e no *chiller*. As variáveis de entrada estão descritas no Quadro 2.

Quadro 2. Parâmetros de abate definidos para análise de correlação com absorção de água em carcaças de frango.

Parâmetro	Descrição
Turno	Turno de produção
Linha	Linha de produção
Velocidade da Linha	Velocidade da linha
Lote	Lote do avicultor
Carga	Carga do lote do avicultor
Sexo	Sexo do animal
Raça	Raça do animal
T_Tanque1	Temperatura tanque de escaldagem 1
T_Tanque2	Temperatura tanque de escaldagem 2
Temp_Tanque1	Tempo de retenção no tanque de escaldagem 1
Temp_Tanque2	Tempo de retenção no tanque de escaldagem 2
T_Dep1	Temperatura da 1° depenadeira
T_Dep2	Temperatura da 2° depenadeira
T_Dep3	Temperatura da 3° depenadeira
Peso_carcaça_inicial	Peso inicial da carcaça após a sangria
T_Inicial_P	Temperatura inicial do pré-chiller
T_Final_P	Temperatura final do pré-chiller
T_Inicial_Chiller	Temperatura inicial do chiller
T_Final_Chiller	Temperatura final do chiller
Tempo_retenção_P	Tempo de retenção do pré-chiller
Tempo_resfriamentoT	Tempo de resfriamento total
Tempo_retenção_Chiller	Tempo de retenção do chiller
Peso_Carcaça_Final	Peso final da carcaça após o chiller
% Absorção	Percentual de absorção

Fonte: Autoria Própria (2023).

As variáveis apresentadas no quadro 2 foram coletadas com o processo de abate de frango, ocorrendo conforme o previsto, seguindo o fluxo do processo produtivo. Foram recolhidas 6 carcaças por lote, com a coleta de dados realizada conforme as descrições a seguir.

Foram coletadas amostras no primeiro e segundo turno de produção, ou seja, no período da manhã e da tarde. Também foram recolhidas amostras nas duas linhas de produção do frango, iniciando a partir do setor de escaldagem do frango. A velocidade da linha pode variar de 6.000 aves/hr a 10.000 aves/hr, antes de iniciar as coletas foram analisadas no painel de controle das linhas a velocidade de cada uma. Para cada lote avaliado, foram coletadas as informações de sexagem da ave, macho

fêmea ou lote misto, assim como, informações da raça das aves, ROSS, COBB ou SRD (sem raça definida).

A temperatura nos tanques de escaldagem foi monitorada utilizando um termômetro, com medições realizadas primeiro no 1° estágio do tanque de escaldagem e, em seguida, no 2° estágio do tanque de escaldagem. As temperaturas das depenadeiras foram medidas através de termômetros, com auxílio de luvas, a extremidade do termômetro foi colocada em contato com a água que saía dos bicos de vazão de água das depenadeiras.

Inicialmente, as carcaças foram pesadas após a depenagem, colocadas uma a uma em bacias brancas e pesadas na balança de precisão (Toledo, modelo 2096H), com isso, se obteve o peso inicial da carcaça. Após o resfriamento das carcaças, as mesmas foram pesadas novamente para obter o peso final com água absorvida. As temperaturas do *pré-chiller* e do *chiller* foram registradas utilizando um termômetro, com medições realizadas no início e ao término de cada equipamento. Para medir o tempo de retenção dos frangos dentro do *pré-chiller* e do *chiller* se utilizava um cronometro, quando as carcaças entravam dentro do *pré-chiller* iniciava a contagem e finalizava com a retirada das carcaças na saída do *chiller*.

4.3.1 Percentual de absorção de água pela carcaça

Em cada teste realizado, foram coletadas aleatoriamente seis (6) carcaças íntegras por lote, identificadas por lacre de cor verde, anotado a massa inicial após a depenagem das aves, e a massa final na saída do sistema de resfriamento, para realização do cálculo da água absorvida por cada carcaça representada em percentual utilizou a equação 1.

$$Aw = \frac{P1-P2}{P1} * 100 \quad (1)$$

Onde:

Aw = Percentual de água absorvida

P1 = Peso inicial (g)

P2 = Peso final (g)

Após a passagem de cada amostra pelo sistema de resfriamento, as carcaças foram direcionadas para a pesagem final. Cada amostra devidamente identificada foi pesada em balança (Toledo, modelo 2096H) anotando seu peso final. Para cálculo de absorção foi utilizada a diferença entre a massa final da carcaça e a massa inicial anotada no item anterior dividido pela massa inicial. O valor de absorção foi anotado na planilha referente a cada amostra identificada pelo lacre.

4.3.2 Ferramentas utilizadas para desenvolvimento do modelo

Durante o processo de coleta de dados, os parâmetros obtidos foram transcritos para uma planilha em papel, após a coleta, todos os dados foram digitalizados para uma planilha eletrônica do MS Excel, para assim, transferir os dados em formato específico para a linguagem de programação *Python*.

Para a construção da rede neural foi utilizado o programa de linguagem *Python* no *Google Colab*, utilizando os conceitos de *Backpropagation*. Para construção da rede neural foi necessário a formulação dos algoritmos de entrada e o treinamento da rede, sendo realizado após as coletas de dados.

4.3.3 Google Colab

O *Google Colaboratory*, ou *Google Colab* em sua nomenclatura mais curta, é um serviço com versão gratuita, para executar *Jupyter notebooks*, que não requer instalação e funciona na nuvem. Sua versão gratuita oferece ao usuário acesso à execução utilizando a arquitetura GPU ou TPU, mas essa disponibilidade é limitada. O *Google Colab* possui mais duas edições, Pro e Pro+, na edição Pro o usuário tem acesso a GPUs e TPUS mais rápidas, mais RAM e mais discos para melhor armazenamento de código e variáveis, além de maior tempo de execução e menor tempo de inatividade. A versão Pro+ permite que aplicativos sejam executados em segundo plano mesmo após fechar o navegador, GPUs mais rápidas, mais memória e tempos de execução ainda mais longos. Por esses motivos, o *Google Colab Pro* (Chollet, 2020) foi utilizado no desenvolvimento deste trabalho.

4.3.4 Tratamento dos dados

Após as coletas dos dados, os mesmos foram digitalizados em planilha do MS Excel (Versão 2310), dividida em 24 colunas, onde as 23 primeiras colunas são consideradas os parâmetros de influência (x) e a 24ª coluna é considerada a variável *target* (y), conforme representado na Tabela 2.

Tabela 2. Parâmetros e variáveis.

Parâmetro 1	Parâmetro 2	Parâmetro 3	...	Parâmetro 20	Variável Target
Valor 1,1	Valor 1,2	Valor 1,3	...	Valor 1,23	% Absorção 1,24
Valor 2,1	Valor 2,2	Valor 2,3	...	Valor 2,23	% Absorção 2,24
...	% Absorção 3,24
Valor 118,1	Valor 118,2	Valor 118,3	...	Valor 118,23	% Absorção 4,24

Fonte: Autoria Própria (2023).

A planilha do MS Excel foi convertida em formato .csv para facilitar o carregamento dos dados no ambiente de programação *Python*. Um total de 2.832 informações foram utilizadas, que posteriormente serão divididos em conjuntos de 20% para treinamento e 80% para teste. Esses dados foram submetidos a um processo de tratamento para assegurar maior confiabilidade, visando a criação de um modelo generalizado.

Durante a coleta de dados, foi observado que algumas variáveis apresentaram pouca ou nenhuma variação. Em virtude disso, optou-se por descartar tais variáveis da base de dados, visando evitar possíveis interferências que poderiam tornar o modelo mais complexo e menos preciso. O Quadro 3 apresenta os parâmetros que foram removidos.

Quadro 3. Parâmetros de abate excluídos e motivo da exclusão.

Parâmetro	Motivo
Turno	Coletas somente em dois turnos de produção
Linha	Somente duas linhas de produção
Velocidade da Linha	Velocidade fixa a 10.000 aves/hr
Lote	Diversidade de lotes não contribui com o modelo
Carga	Diversidade de cargas não contribui com o modelo
Sexo	Coletas somente com lotes de fêmeas
Raça	Diversidade de Raças não contribui com o modelo
Peso_carcaça_inicial	Variável já englobada em % de absorção
Peso_Carcaça_Final	Variável já englobada em % de absorção


Fonte: Autoria Própria (2023).

O coeficiente de correlação de Pearson (R) mede o grau de correlação linear entre duas variáveis quantitativas. Representa um índice adimensional com valores entre -1,0 e 1,0, que refletem a força do relacionamento linear entre dois conjuntos de dados (Charnet et al., 2008).

Se r for igual a 1, representa a correlação positiva entre duas variáveis, enquanto se r for igual a -1, consiste em uma correlação negativa perfeita entre as duas variáveis; assim, quando uma aumenta, a outra diminui, indicando que as duas variáveis não são linearmente dependentes uma da outra. Porém, a presença de outro elemento não linear é possível, portanto, se o resultado r for mais próximo de 0, devendo ser investigado.

Neste trabalho, o coeficiente de correlação de Pearson foi utilizado para retirar as variáveis que menos se relacionaram com a absorção com a finalidade de otimizar o modelo. De acordo com o mapa de calor (Figura 4), pode-se observar que os atributos avaliados apresentaram valores entre -0,56 e 0,53. Com base nesse resultado pode-se excluir os atributos com menores correlações.

Figura 4. Mapa de calor dos atributos avaliados.



Fonte: Autoria Própria (2023).

Com base no mapa de calor, os atributos excluídos foram conforme Tabela 3:

Tabela 3. Parâmetros excluídos.

Parâmetro	Descrição	Correlação
T_inicial_Chiller	Temperatura inicial chiller	-0,0012
T_final_Chiller	Temperatura final chiller	0,083
Tempo_retenção_P	Tempo de retenção pré-chiller	0,035
Tempo_retenção_Chiller	Tempo de retenção chiller	-0,014

Fonte: Autoria Própria (2023).

Com a exclusão desses parâmetros, foram analisados os parâmetros não excluídos para a obtenção de um modelo com melhor correlação.

4.3.5 Desenvolvimento da programação

Para o desenvolvimento da programação da rede neural em linguagem *Python*, se utilizou a biblioteca *TensorFlow*. Segundo Ribeiro e Guimarães (2016), a *TensorFlow* é uma biblioteca de código aberto criada pela equipe do *Google Brain* para aprendizado de máquina e pesquisa de redes neurais profundas. Ele vem crescendo muito pelo fato de seu desempenho por utilizar XLA, um poderoso

compilador de álgebra linear que torna a execução mais rápida, rodando em CPUs, GPUs, TPUs e outros.

Outro ponto positivo do *TensorFlow* é a sua flexibilidade. Existem APIs que ajudam, ainda mais, o usuário a utilizar suas tecnologias, para a programação da rede neural utilizou a *API Keras*. Para Ribeiro e Guimarães (2016), o *Keras* tem como vantagem ter uma interface mais simples e otimizada para casos mais comuns, facilitando na criação de um modelo de redes neurais profundas, onde o seu entendimento é facilitado.

Ainda segundo Ribeiro e Guimarães (2016), as bibliotecas *pandas*, *keras* e da classe *Sequential* facilitam a criação da estrutura da rede, que tem como característica de ser ordenada e sequencial (entrada, camada(s) ocultas e saída). Neste trabalho, importou-se de *keras.layers* a classe *Dense*, que representa que cada um dos neurônios é ligado com todos os outros da camada subsequente. O *Pyplot* será utilizado para mostrar o gráfico. Para leitura e pré-tratamento dos dados, o arquivo precisa estar em formato *.csv*, o mesmo terá seu conteúdo armazenado em um *data frame* denominado de *df*. Foi necessário, para fim de cálculos matemáticos, tratar a coluna da absorção para que contenha números decimais ao invés de strings/textos.

4.3.6 Desenvolvimento do modelo

Os dados para treinamento e para teste devem ser definidos, pois, ao terminar o processo de aprendizagem, é gerado um modelo com os pesos ajustados, e sobre eles é aplicado esses dados teste para saber sua eficiência. Definindo que o conjunto de teste é igual a 20% dos dados contidos no *dataset*.

Após a definição dos conjuntos de dados testes e treinos, foi utilizada a classe *StandardScaler* do pacote *sklearn.preprocessing* para padronizar (ou escalar) as características do seu conjunto de dados. O *StandardScaler* é usado para padronizar as características, removendo a média e escalonando para a variância unitária. Isso é importante em muitos algoritmos de aprendizado de máquina que são sensíveis à escala das variáveis.

Nesta linha, foi ajustado o *StandardScaler* com os dados de treino (*X_train*) e, ao mesmo tempo, transformando esses dados para que eles sejam padronizados. Já o método *fit_transform* calcula a média e o desvio padrão dos dados de treino e aplica a transformação nesses dados.

Em seguida, foram utilizados os parâmetros (média e desvio padrão), calculados a partir dos dados de treino para transformar os dados de teste (X_{test}). Isso garante que os dados de teste sejam transformados da mesma maneira que os dados de treino, mantendo a consistência na escala.

Após, foi criado um modelo sequencial (*Sequential*) em *Keras*. Um modelo sequencial é apropriado para uma pilha linear de camadas, onde é possível, de forma simples, adicionar camadas uma após a outra. Neste modelo, utilizou-se a camada de entrada com 14 neurônios, uma camada intermediária com 7 neurônios e a camada de saída com 1 neurônio.

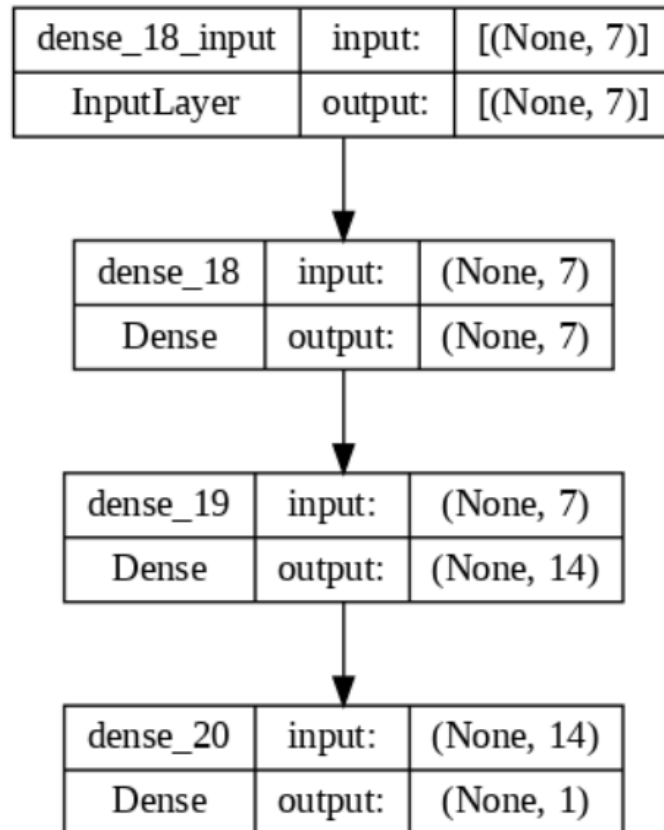
A função *Dense* cria uma camada totalmente conectada (ou densa) com 8 unidades (ou neurônios). O $input_shape=(X_train.shape[1])$ especifica a forma dos dados de entrada que serão alimentados na rede. O $X_train.shape[1]$ é o número de características (ou atributos) nos dados de treinamento. A função de ativação '*relu*' significa que a ativação da unidade será calculada usando a função de ativação *Relu* (*Rectified Linear Unit*), que é comumente usada em redes neurais para introduzir não-linearidades.

A linha, *Dense(1, activation='linear')*, cria a segunda camada da rede neural. É outra camada densa com uma única unidade, indicando que esta rede neural é usada para problemas de regressão, onde o objetivo é prever um valor contínuo. A função de ativação '*linear*' significa que não há nenhuma função de ativação aplicada nesta camada, o que implica que a saída será uma combinação linear das entradas.

Logo, este código define um modelo de rede neural com duas camadas intermediárias e uma camada de saída, a primeira camada de entrada com 7 neurônios e ativação *Relu*, a segunda camada intermediária com 14 neurônios e ativação *Relu*, e a camada de saída com 1 neurônio e ativação linear. Este é um exemplo simples de uma arquitetura de rede neural para um problema de regressão.

A seguir, há uma representação em blocos e outra clássica no formato de círculos e conexões para fins de visualização:

Figura 5. Representação em blocos do modelo utilizado para rede neural.



Fonte: Autoria Própria

4.3.7 Otimização do modelo

Para otimizar o modelo, com o intuito de conseguir resultados mais próximos ao real, utilizou-se o seguinte comando:

```
model.compile(optimizer='adam', loss='mean_squared_error')
```

O otimizador é um algoritmo que ajusta os pesos da rede neural durante o treinamento. O *'adam'* refere-se a um otimizador popular chamado *Adam*. O *Adam* é uma variação do método de descida de gradiente estocástico (SGD) que ajusta as taxas de aprendizado de cada parâmetro individualmente, proporcionando uma convergência mais rápida e eficiente durante o treinamento da rede neural.

A função de perda (ou *loss function*) é uma medida que quantifica o quão bem o modelo está performando em relação aos dados de treino. Já o *'mean_squared_error'* é a função de perda de erro médio quadrático, que é frequentemente usada em problemas de regressão. Ela calcula a média dos

quadrados das diferenças entre as previsões do modelo e os valores reais. O objetivo durante o treinamento é minimizar essa função de perda, ou seja, reduzir o erro quadrático médio entre as previsões do modelo e os valores reais.

4.3.8 Avaliação do modelo

Para avaliar o modelo, utilizou-se como base o erro quadrático médio (MSE), erro absoluto (MAE), Coeficiente de Determinação e o coeficiente de correlação nos dados de teste.

A média dos erros absolutos (Erro Absoluto Médio ou MAE na sigla em Inglês) é uma métrica pouco afetada por pontos com valores anormalmente extremos, também chamados “pontos singulares” (ou “outliers” em Inglês), o MAE é considerado preciso e robusto como medida da habilidade de modelos numéricos em reproduzir a realidade (Fox, 1981). Na modelagem o código para a determinação do MAE foi definido por:

```
from sklearn.metrics import mean_absolute_error
MAE = mean_absolute_error(y_test, y_pred)
print(MAE)
```

O Erro quadrático médio (MSE na sigla em inglês), Wilks (2006) descreve que o MSE é uma métrica frequentemente utilizada na verificação da acurácia de modelos numéricos, é similar ao MAE, entretanto é mais sensível aos grandes erros, pois eleva as diferenças individuais ao quadrado. O MSE é sempre positivo, caso o MSE = 0 demonstra uma simulação perfeita. Na modelagem o código para a determinação do MSE foi definido por:

```
loss = model.evaluate(X_test_scaled, y_test, verbose=0)
print("Erro quadrático médio nos dados de teste (RSME):", loss)
```

O comando *X_test_scaled* refere-se aos dados de teste padronizados utilizados para avaliar o modelo. Estes dados passaram pelo mesmo processo de escala que os dados de treino, garantindo que a escala seja consistente para ambos os conjuntos. O comando *y_test* representa os rótulos correspondentes aos dados de teste. Estes são os valores reais que o seu modelo tentará prever.

A função *model.evaluate* calcula a perda (ou erro) do modelo nos dados de teste. A perda é calculada com base nas previsões do modelo para os dados de teste (*X_test_scaled*) e nos rótulos reais (*y_test*). A função de perda que se especificou durante a compilação do modelo (*mean_squared_error*, neste caso) é utilizada para calcular a perda. Já a função *verbose=0* indica que não se deseja que mensagens de progresso sejam exibidas durante a avaliação.

Segundo Marcuzzo (2014). O coeficiente de correlação é igual à raiz quadrada do coeficiente de determinação, que por sua vez é igual ao quadrado do coeficiente de correlação. Assim a partir do valor do coeficiente de determinação pode-se obter o valor do coeficiente de correlação. O coeficiente de determinação é sempre positivo, variando de 0 a 1, enquanto o coeficiente de correlação (*r*) pode admitir valores negativos e positivos, variando de -1 a 1 , ou seja, $-1 \geq r \leq +1$. Valores de *r* igual ou próximos de 1 ou -1 indica que determina uma intensa relação entre as variáveis: no primeiro caso a relação é direta, enquanto que no segundo a relação é inversa. Valores iguais ou próximos de zero, significa que existe nenhuma ou pouca relação entre as variáveis explicativas e explicadas.

Sabe-se que o coeficiente de determinação indica o quanto a curva de regressão explica o ajuste da curva, enquanto o coeficiente de correlação deve ser usado como uma medida de força da relação entre as variáveis. Entende-se que o coeficiente de correlação tem um valor único para o conjunto de dados testados e que padroniza dentro dos seus limites as variações da covariância.

Para determinar o coeficiente de Determinação na modelagem em python, utilizou o código abaixo.

```
from sklearn.metrics import r2_score
y_pred = previsoes
R2 = r2_score(y_test,y_pred)
print(R2)
```

O coeficiente de correlação amostral (r) está relacionado ao coeficiente de determinação, através da seguinte equação:

```
import math
y_pred = previsoes
R2 = r2_score(y_test, y_pred)
raiz_quadrada = math.sqrt(R2)
print(raiz_quadrada)
```

5. RESULTADOS E DISCUSSÃO

Após conduzir testes até alcançar a configuração de rede representada na Figura 5, tendo a absorção como a variável de saída, apresentam-se os resultados mais significativos para os parâmetros selecionados devido às suas correlações mais robustas. O coeficiente de correlação mais elevado atingido foi de 0,8913. Para atingir esse coeficiente, diversos testes foram executados utilizando o algoritmo, os quais são detalhados na Tabela 4.

Tabela 4. Configuração com melhor coeficiente de correlação para predição de absorção.

	Parâmetros/Resultados	Valor
Parâmetros	Número de camadas	1
	Neurônios por 1° camada intermediária	7
	Neurônios por 2° camada intermediária	14
	Épocas	5000
Resultados	Erro médio quadrado (MSE)	0.0001161
	Erro absoluto (MAE)	0.007534
	Coefficiente de Determinação	0,794470
	Coefficiente de Correlação	0,891330

Fonte: Autoria Própria (2023).

O coeficiente de correlação está apresentado na Tabela 4, destacando-se que o valor de R para a estrutura com sete (7) neurônios na primeira camada intermediária e quatorze (14) neurônios na segunda camada intermediária foi o mais próximo de um (1), representando o resultado mais eficaz. Isso sugere que os dados preditos estão altamente concordantes com os valores reais.

Quanto ao Erro Médio Quadrático, também registrado na Tabela 4, o resultado obtido foi de 0,011. Essa baixa magnitude indica que a rede é capaz de reproduzir de maneira precisa o percentual de absorção das amostras utilizadas na sua construção.

O estudo conduzido por Pinto (2021) empregou um algoritmo de aprendizado de máquina para antecipar a absorção de água em carcaças de frango, alcançando um coeficiente de correlação de 0,63 e um Erro Médio Quadrático de 0,1417. A autora destaca que tais resultados foram obtidos sob condições em que as variáveis do processo produtivo estavam mais alinhadas com os padrões preconizados. Nestas circunstâncias, a adaptação mais eficiente aos dados experimentais ocorreu, uma vez

que a qualidade da carcaça não interferiu nas etapas. Esse contexto fortaleceu o aprendizado da rede, facilitando a previsão precisa dos resultados de absorção.

O estudo conduzido por Silva (2021), que analisou os fatores pré-abate no Dripping test e na absorção, resultou em um coeficiente de correlação de 0,501 e um erro quadrado médio de 0,1151. O autor afirmou que essa correlação é razoável, embora existam variáveis no processo que não foram consideradas no estudo e que podem interferir no resultado da absorção das carcaças.

No presente trabalho, observa-se uma situação semelhante. A exclusão de alguns parâmetros otimizou o resultado. Entretanto, apesar da correlação ser considerada boa, ainda não atingiu o valor ideal, que seria maior ou igual a 0,90.

Silva (2021) cita em seu estudo Beledelli (2014), que também empregou uma RNA com duas camadas intermediárias radiais e o algoritmo *gradiente descent backpropagation* para treinar dados e avaliar as variáveis do processo. O coeficiente de correlação obtido foi de 0,9265. Mesmo considerando variáveis que influenciam o processo de resfriamento das carcaças de frango, a RNA aplicada mostrou-se satisfatória em prever a temperatura final das carcaças.

Klassen et al. (2016) empregaram um modelo simplificado baseado em Redes Neurais Artificiais (RNAs) para prever a temperatura das carcaças de frango na saída dos *chillers* de resfriamento. No experimento, inicialmente foram utilizadas vinte e cinco (25) variáveis de entrada. No entanto, ao longo do processo, foram definidas as variáveis mais relevantes, como massa inicial, vazão de água, intensidade do borbulhamento, temperatura e tempo de retenção no *chiller*. Com a redução dessas variáveis, foi alcançado um coeficiente de correlação de 0,97201, indicando uma precisão significativa. A Tabela 5 resume os resultados encontrados pelos diferentes autores e neste trabalho.

Tabela 5. Comparação dos resultados.

Autor	Ano	Erro Quadrático Médio	Coefficiente de Correlação
Autoria própria	2023	0,0116	0,891
Pinto	2021	0,1417	0,630
Silva	2021	0,1151	0,501
Klassen	2016	-	0,972
Belledeli	2014	-	0,926

Fonte: Autoria Própria (2023).

Após a conclusão da modelagem final da rede, os parâmetros adquiriram pesos que refletem a importância de cada um na predição do percentual de absorção de água em carcaças de frango. A Tabela 6 ilustra essa importância, permitindo a observação detalhada do impacto de cada parâmetro.

Tabela 6. Variáveis com maior impacto no percentual de absorção de água em carcaças de frango


Parâmetros	Faixas	Importância para o modelo
Temperatura do 2° tanque de escaldagem	58.7° C – 61.7°C	0.014184
Temperatura inicial do <i>pré-Chiller</i>	2.8°C – 12.6°C	0.007995
Temperatura do 1° tanque de escaldagem	39.9°C – 51.9°C	0.004868
Temperatura final do <i>Pré-Chiller</i>	0.4°C – 7.6°C	0.004819
Temperatura Depenadeira 3	49.0°C – 58.3°C	0.004342
Temperatura Depenadeira 1	32.5°C – 59.3°C	0.003780
Temperatura Depenadeira 2	49.0°C – 59.0°C	0.003487

Fonte: Autoria Própria (2023).

O parâmetro que exerceu o maior impacto foi a temperatura do segundo estágio do tanque de escaldagem, destacando-se com uma importância para o modelo de 0.014184. Engel (2018), em seu estudo, investigou os efeitos dos tanques de escaldagem na absorção de água em carcaças de frango. A autora categorizou dois tipos de escaldagem com base na temperatura da água de escalda: escaldagem branda, com uma faixa de até 56°C a 59°C, e escaldagem severa, com valores superiores a 59°C.

A faixa de temperatura adotada neste trabalho varia de 58.7°C a 61.7°C, devido ajustes realizados por operadores afim de melhorarem outros indicadores dentro do processo. O modelo indica que, conforme a temperatura aumenta, a absorção tende a diminuir. Este padrão é corroborado pelo gráfico de dispersão a seguir, onde se pode observar esse efeito.

Figura 6. Gráfico de dispersão entre a temperatura de escaldagem do 2º tanque de escaldagem e o percentual de absorção.



última realizada por imersão em água gelada e/ou água e gelo ou passagem por túnel de resfriamento, obedecendo aos critérios técnicos específicos.

No estudo conduzido por Oliveira (2016), concluiu-se que três fatores exercem influência direta na capacidade de retenção de água por carcaças de frango. O primeiro está relacionado à temperatura da água do *pré-chiller*, onde quanto mais elevada a temperatura, maior é o percentual de água absorvida pelas carcaças. O segundo refere-se ao sistema de borbulhamento, conectado ao *chiller* e *pré-chiller*, contribuindo para um aumento satisfatório no percentual de absorção de água. O terceiro aspecto diz respeito ao tempo de retenção, sendo considerado ideal um período de sessenta (60) segundos. A combinação controlada desses três elementos é considerada ideal, permitindo que a quantidade de água absorvida pelas carcaças aumente, porém permaneça dentro dos limites estabelecidos pela legislação.

No contexto do *pré-chiller*, Oliveira (2016) descreve que cerca de 60% da água total absorvida durante o processo de resfriamento ocorre nesse estágio. Isso se deve ao fato de que, nesse momento, ainda não ocorreu a queda do pH *pós mortem* e a formação de ácido láctico na carcaça. Além disso, a água do *pré-chiller* deve estar relativamente fria, aproximadamente 16°C.


Oliveira (2016) destaca que os poros desempenham um papel significativo na absorção de água, sendo responsáveis por aproximadamente 25% do total absorvido durante o processo. Esses poros permanecem abertos à temperatura da ave ao final da evisceração, aproximadamente 40°C. Se a água do *pré-chiller* estiver relativamente fria, os poros se fecham rapidamente, reduzindo a quantidade de água absorvida. Além disso, um tempo de processo insuficiente, inferior a 15 minutos, resultará em uma hidratação extremamente baixa.

Os resultados de Pinto (2021) indicam que alguns dos principais atributos com maior influência no processo de absorção, conforme classificados pelo algoritmo, incluem massa média, linha de produção, tempo de retenção no *pré-chiller*, peso inicial da carcaça, temperatura do *pré-chiller* e temperatura de escaldagem. Durante a pesquisa, observou-se que, embora a absorção de água pelas carcaças de frango possa ocorrer em outras fases do processo de abate, o pré-resfriamento é a etapa em que ocorre a maior absorção de água. Nessa fase, as carcaças são submersas em um tanque com água gelada por um período específico. Os fatores mencionados no estudo, como massa média, tempo de retenção no *pré-chiller*, peso inicial da carcaça,

temperatura do *pré-chiller* e temperatura de escaldagem, interagindo, provocando alterações bioquímicas nas carcaças e aumentando a absorção de água.

No modelo apresentado neste artigo, observa-se que, semelhantemente aos dados de Pinto (2021), quanto maior a temperatura inicial do *pré-chiller*, maior será o percentual de absorção de água nas carcaças de frango, pode-se observar esse fenômeno na figura 7.

Figura 7. Gráfico de dispersão entre a Temperatura inicial do pré-chiller e o percentual de absorção.



Fonte: Autoria Própria (2023).

A figura 7 demonstra o comportamento dos dados coletados, nela pode-se observar que em temperaturas maiores logo no início do *pré-chiller* o percentual (%) de absorção tende a aumentar, enquanto em temperaturas menores do *pré-chiller* esse percentual (%) tende a ser menor, sendo diretamente proporcional.

Em resumo, a análise dos resultados indica que o modelo preditivo desenvolvido, utilizando redes neurais artificiais, apresentou uma correlação significativa de 0,8913 para a absorção de água em carcaças de frango. Destacam-se variáveis relacionadas aos estágios de resfriamento, como a temperatura do segundo tanque de escaldagem, como fatores-chave. Entretanto, reconhece-se que, apesar dos avanços, há desafios a serem enfrentados, considerando a complexidade do ambiente avícola. Esses resultados fornecem visões importantes sobre o tema, abrindo caminho para aprimoramentos contínuos e adaptações do modelo às variações na produção.

6 CONCLUSÃO

O desenvolvimento e análise do modelo para prever o percentual de absorção de água em carcaças de frango proporcionou uma compreensão mais aprofundada das variáveis existentes no processo produtivo. O coeficiente de correlação alcançado, atingindo 0,8913 com a configuração específica da rede neural, destaca a eficácia do modelo em antecipar a absorção com precisão.

A atenção dedicada aos parâmetros relacionados aos estágios de escaldagem, especialmente a temperatura do segundo estágio do tanque de escaldagem, destaca a importância desses fatores específicos na dinâmica do fenômeno. O modelo também apresentou relevância significativa para as temperaturas do pré-chiller. Ao fornecer oportunidades sobre a influência desses elementos, o modelo contribui para uma compreensão mais aprofundada da absorção, permitindo que a indústria avícola ajuste estrategicamente seus processos para otimizar as etapas que influenciam diretamente na absorção de água em carcaças de frango.

Embora os resultados deste estudo validem observações anteriores, é interessante reconhecer a necessidade contínua de aprimorar o modelo neural, dada a natureza existente do ambiente de produção avícola. A sensibilidade das variáveis e a complexidade das interações entre os diversos estágios do processo indicam que a melhoria constante é crucial para manter a relevância e a eficácia do modelo ao longo do tempo. A busca por uma compreensão mais profunda dos fatores que influenciam a absorção de água em carcaças de frango deve ser encarada como um esforço contínuo, visando refletir de maneira mais precisa os detalhes do ambiente de produção em constante evolução.

O modelo proposto contribui não apenas para a compreensão teórica da absorção de água em carcaças de frango, mas também como ferramenta prática para otimizar operações nas instalações de processamento de carne de aves. Ao direcionar a produção de carcaças com características ideais de absorção de água, a indústria pode superar as expectativas de qualidade, promovendo uma produção mais eficiente e sustentável. O contínuo refinamento desse modelo, alinhado aos avanços tecnológicos e às exigências do setor, representa um passo significativo em direção a práticas mais eficientes e sustentáveis na produção avícola.

REFERÊNCIAS

- ABDALLA, S.A.A.; JENSEN, J.F. Effect of different scalding temperatures on carcasses and meat quality in broilers. **European Poultry Science**, p. 249–253, 1997.
- ALVES, N.E. do N.; ALVES, M.A. **Redes Neurais Artificiais Aplicadas na Predição de Movimento do bitcoin**. Formiga: Instituto Federal de Minas Gerais, 2020.
- ANDRADE, P.L. **Tecnologia de tratamento de carnes e derivados**. 2. ed. Brasília: NT Editora, 2019. 114 p.
- ARAÚJO, J.M.A. **Química dos Alimentos - Teoria e prática**. Viçosa: Universidade Federal de Viçosa, 1995.
- ASSOCIAÇÃO BRASILEIRA DE PROTEÍNA ANIMAL (ABPA). **Relatório Anual 2022**. ABPA, 2022. Disponível em < <https://abpa-br.org/mercados/#relatorios> > Acesso: 21 set. 2022.
- BORGES, L.E. **Python para desenvolvedores**. Rio de Janeiro: Editora Novatec, 2014, 360 p.
- BRACCINI, V.P.; ARBELLO, D.D.R.; JIMENEZ, M.S.E.; ERHARDT, M.M. et al. Tipos de fibras musculares, identificação, características e qualidade da carne. **Brazilian Journal of Development**, v.7, n.3, p. 21180-21190, 2021.
- BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Animal**. MAPA, 2022. Disponível em: <<http://www.agricultura.gov.br>> Acesso em: 22 set. 2022.
- BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Portaria nº74, de 07 de maio de 2019. **Altera a Portaria nº. 210, de 10 de novembro de 1998**. Brasília: 2019.
- BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. DCI/DIPOA. Portaria nº.210, de 10 de novembro de 1998. **Aprova o Regulamento Técnico da Inspeção Tecnológica e Higiênico Sanitária da Carne de Aves**. Diário Oficial da União, Brasília, 26 de novembro de 1998, Seção 1, p. 226.
- BRESSAN, M.C.; BERAQUET, N.J. Tratamentos de pré-resfriamento e resfriamento sobre a qualidade de carne de peito de frango. **Ciência e Tecnologia de Alimentos**, Campinas, v. 24, n. 2, p. 230-235, 2004.
- BROSSI, C.; CONTRERAS-CASTILLO, C.J.; AMAZONAS, E.A.; MENTEN, J.F.M. Estresse térmico durante o pré-abate em frangos de corte. **Ciência Rural**, v. 39, n. 4, 2009.
- CARCIOFI, B.A.M. **Estudo do resfriamento de carcaças de frango em chiller de imersão em água**. Florianópolis: Departamento de Engenharia Química e de Engenharia de Alimentos. Universidade Federal de Santa Catarina, 2005.

CARCIOFI, B.A.M.; LAURINDO, J.B. Water uptake by poultry carcasses during cooling by water immersion. **Chemical Engineering and Processing: Process Intensification**, v. 46, n. 5, p. 444–450, 2007.

CHARNET, R.; FREIRE, C.A.L.; CHARNET, E.M.R.; BONVINO, H. **Análise de modelos de regressão linear**: com aplicações. 2a ed. Campinas: Editora da UNICAMP, 2008.

CHOLLET, F. **Deep Learning with Python**. 2. ed. Manning, 2020. ISBN 9781617296864.

COTTA, J.T.B. **Frangos de Corte – Criação, Abate e Comercialização**. São Paulo: Aprenda fácil, 2017.

DATA SCIENCE ACADEMY. **Capítulo 3 – O Que São Redes Neurais Artificiais Profundas ou Deep Learning?** Data Science Academy, 2022. Disponível em <<https://www.deeplearningbook.com.br/o-que-sao-redes-neurais-artificiais-profundas/#content>> Acesso: 15 out. 2022.

EMBRAPA, Empresa Brasileira de Pesquisa Agropecuária. **Qualidade da carne das aves**. Brasília: Ministério da Agricultura, Pecuária e Abastecimento. Publicado em: 2017. Disponível em: <<https://www.embrapa.br/qualidade-da-carne/carne-de-aves>>. Acesso: 22 ser. 2022.

ENGEL, M. **Impacto das condições de escaldagem em carcaças de frango durante o processamento industrial**. 2018. 45 f. Dissertação (Mestrado em Tecnologia de Alimentos) – Universidade Tecnológica Federal do Paraná, Medianeira, 2018.

FLUCKEY, W.M.; SANCHEZ, M.X.; MCKEE, S.R.; SMITH, D.; PENDLETON, E.; BRASHEARS, M.M. (2003) Establishment of a microbiological profile for an air-chilling poultry operation in the United States. **Journal of Food Protection**, v. 66, n. 2, p. 272-279.

FOX, D. G. Judging Air Quality Model Performance. **Bulletin of the American Meteorological Society**, v. 62, p. 599- 609, 1981

GHERARDI, S.R.M. **Abate e Processamento de Carne e Frango**. Ministério da Educação, Instituto Federal Goiano, 2013.

GOMIDE, L.A.M.; RAMOS, E.M.; FONTES, P.R. **Ciência e qualidade da carne**: fundamentos Viçosa: Editora UF, 2013, 197p.

GUARNIERI, P.D. **Manejo pré-abate em aves**: Efeito do banho no grau de estresse em frangos e qualidade da carne. 2003. 62f. Dissertação (Mestrado em Ciências dos Alimentos) – Universidade de São Paulo, São Paulo, 2003.

HAUTRIVE, T.P.; MARQUES, A.C.; KUBOTA, E.H. Avaliação da composição centesimal, colesterol e perfil de ácidos graxos de cortes cárneos comerciais de

avestruz, suíno, bovino e frango. **Alimentos e Nutrição**, Araraquara, v. 23, n. 2, p. 327-334, abr./jun. 2012.

JAMES, C.; VINCENT, C.; DE ANDRADE LIMA, T.I.; JAMES, S.J. (2006) The primary chilling of poultry carcasses—a review. **International Journal of Refrigeration**, v. 29, n. 6, p. 847-862.

KLASSEN, K.; LISOWSKY, P.; MESSALL, D. The Role of Auditors, Non-Auditors, and Internal Tax Departments in Corporate Tax Aggressiveness. **The Accounting Review**, v. 110, n. 9, p. 1689–1699, 2016.

KLASSEN, T.; MARTINS, T.D.; CARDOZO FILHO, L.; SILVA E.A. Modelagem do sistema de resfriamento por imersão de carcaças de frangos utilizando redes neurais artificiais. **Acta Scientiarum Technology**, v. 31, n. 2, p. 201-205, 2009.

LEAL, M.C. **Utilização de algoritmos de aprendizagem de máquina para predição de absorção de água nas carcaças de frango**: aplicação de redes neurais artificiais. Francisco Beltrão: Universidade Tecnológica Federal do Paraná, 2021.

LUCHIARI FILHO, A. **Pecuária da carne bovina**. São Paulo: Luchiari Filho, 2000. 135p.

LUDTKE, C.B.; CIOCCA, J.R.P.; DANDIN, T.; BARBALHO, P.C.; VILELA, J.A. **Abate humanitário de aves**. São Paulo: Editora WSPA, 2010.

LUDTKE, C.B.; VILELA, J.A.; COSTA, A.D. **Abate humanitário de aves**. Nova Odessa: Anais Workshop de Bioética e Bem-estar Aplicados aos Animais de Produção, 2009.

MARCUZZO, F. **Modelagem Hidrológica Utilizando Regressão: Conceituação Matemática**, Logaritmização e Avaliação. XII Simpósio de Recursos Hídricos do Nordeste. Natal, 2014.

MARSLAND, S. **Machine Learning: An Algorithmic Perspective**. Hoboken: CRC Press, 2014.

MARTINS, T.D.; KLASSEN, T.; CANEVESI, R.L.S.; BARELLA, R.A.; CARDOZO FILHO, L.; SILVA, E.A. Modeling the Water Uptake by Chicken Carcasses during Cooling by Immersion. **Revista Ciência e Tecnologia de Alimentos**, v. 31, n. 3, p. 571–576, 2011.

MASTROGIACOMO, V. **O mundo do frango**: cadeia produtiva de carne de frango. Criciúma, SC, 2006.

MATSUMURA, E.M. **Perspectivas para conservação e reuso de água na indústria de alimentos**: estudo de uma unidade de processamento de frangos. São Paulo: Universidade de São Paulo, 2007.

MCCULLOCH, W.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, n. 1, p. 115-133, 1943.

MENDES, A.A. Jejum pré-abate em frangos de corte. **Revista Brasileira de Ciência Avícola**, v. 2, p. 199-209, 2001.

MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO (MAPA). **Manual de procedimentos de inspeção e fiscalização de aves e derivados em estabelecimentos sob inspeção federal (SIF)**. MAPA, Brasília, DF, 2021.

MONTEIRO, G.O.A; SILVA, L.A.R.; ABREU, V.L.S.; COPAT, L.L.P.; NASCIMENTO, K.M.R.S. **Manejo pré-abate de frangos de corte**. Ministério da Educação, Fundação Universidade Federal de Mato Grosso do Sul, 2017.

OLIVEIRA, B. **Avaliação dos parâmetros que influenciam na capacidade de retenção de água em carcaças de frango inteiro**. Ponta Grossa: Universidade Tecnológica Federal do Paraná, 2016.

OLIVO, R. **O mundo do frango: cadeia produtiva de carne de frango**. Criciúma, SC, 2006. 680p.

ORDONEZ, J.A.; RODRIGUEZ, M.I.C.; ÁLVAREZ, L.F.; SANZ, M.L.G. et al. **Tecnologia de Alimentos: Alimentos de Origem Animal**. Porto Alegre: Editora Artmed, 2005.

PINTO, M.C.L.; ALFARO, A.T.; BRUSAMARELLO, C.Z.; WEBER, C.I.; SILVA, R.R. da. Utilização de algoritmos de aprendizagem de máquina para predição de absorção de água nas carcaças de frango. **Brazilian Journal of Development**, v. 7, n. 1, p. 2391–2402, 2021.

PORTAL DO AGRONEGÓCIO. **Consumo de carne de frango cresce durante a pandemia**. Portal do Agronegócio, 2021. Disponível em <<https://www.portaldogronegocio.com.br/pecuaria/avicultura/noticias/consumo-de-carne-de-frango-cresce-durante-a-pandemia>> acesso em 16 set. 2022.

REALI, E.H. **A utilização de inteligência artificial (redes neurais artificiais) no gerenciamento da produção de frangos de corte**. 2004. 127f. Dissertação (Mestrado em Ciências Veterinárias) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2004.

RIBEIRO, M.M.; GUIMARÃES, S.S. Redes Neurais utilizando tensorflow e keras. **Revista UNIFENAS**, v.1, 2016.

ROÇA, R.O. **Composição química da carne**. Botucatu: UNESP, Departamento de Gestão e Tecnologia Agroindustrial, 2008.

ROSA, K.R. **Fatores que interferem na absorção de água em carcaças de frango**. Cuiabá: Instituto Federal de Educação Ciência e Tecnologia de Mato Grosso, 2014.

ROSSETTI, J.C. Avicultura: atividade de peso para a economia brasileira. **Casa da Agricultura**, ano 17, n. 3, p. 3, jul./ago./set./2014.

SANT'ANA, V. **Análise dos fatores que afetam a temperatura e absorção de água em carcaças de frango em Chiller industrial.** Universidade Federal do Rio Grande do Sul, Instituto de ciência e tecnologia de alimentos. Porto Alegre, 2008.

SANTOS, D.V.S. **Absorção de água em carcaças de frango:** avaliação da eficiência dos métodos oficiais do Brasil. Universidade Federal da Bahia, Cruz das Almas - BH, 2012.

SILVA, I.N.; SPATTI, D.H.; FLAUZINO, R.A. **Redes neurais artificiais para engenharia e ciências aplicadas.** São Paulo: Editora Artliber, 2010.

SILVA, T.F. **Avaliação dos impactos dos fatores de pré-abate no dripping test de frango utilizando redes neurais artificiais.** 2021. 79f. Dissertação (Mestrado em Tecnologia de Alimentos) - Programa de Pós-Graduação em Tecnologia de Alimentos, Universidade Tecnológica Federal do Paraná, Francisco Beltrão, 2021.

TAVERNARI, F.C.; ALBINO, L.F.T.; ARAÚJO, W.A.G. Manejo pré-abate de frangos de corte. **Revista CFMV**, v. 15, n. 56, 2012.

VALSECHI, O.A. **Aditivos.** Tecnologia de produtos agrícolas de origem animal. Universidade Federal de São Carlos, São Paulo, 2001.

VALSTA, L.M.; TAPANAINEN, H; MANNISTO, S. Meat Fats in Nutrition. **Meat Science**, v. 70, p. 525-530, 2005.

VENTURINI, K.S.; SARCINELLI, M.F.; SILVA, L.C. **Produção de Bovinos:** Tipo Carne. Vitória: Universidade Federal do Espírito Santo, Boletim Técnico, 2007.

VIEIRA, V.M. **Redes neurais artificiais:** uma aplicação em petrofísica e estudo dos efeitos de estímulos persistentes. Maceió: Universidade Federal de Alagoas, Instituto de Física, 2007.

WILKS, D. S. **Statistical Methods in the Atmospheric Sciences.** International Geophysics Series. 2a. Edição, Estados Unidos da América, Academic Press, v. 91, 2006. 627 p.