

**CENTRO ESTADUAL DE EDUCAÇÃO TECNOLÓGICA “PAULA SOUZA”**

**FACULDADE DE TECNOLOGIA DE BEBEDOURO**

**TECNOLOGIA EM BIG DATA NO AGRONEGÓCIO**

**PREVISÃO DE MEDIDA DE PESO EM BOVINOS POR  
IMAGENS UTILIZANDO REDES NEURAIAS  
CONVOLUCIONAIS**

**AUTOR: JOSÉ LUCAS GOMES**

**ORIENTADOR: RENAN GUILHERME NESPOLO**

**BEBEDOURO**

**2024**

*Corte sua própria lenha.*

*Assim, ela aquecerá*

*você duas vezes.*

*-Henry Ford*

## **DEDICATÓRIA**

Dedico esse trabalho primeiramente à minha família, minha mãe Vanda Gomes que sempre esteve ao meu lado, meu pai Luciano Gomes, minha irmã Anna Julia Gomes, minha avó Jacira Marlene Maruyama, minha tia Tereza Maruyama, minha amada namorada Fernanda Bossolani e todos os meus amigos.

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus que permitiu ter saúde suficiente para desenvolver esse trabalho, agradeço a minha família, minha mãe, meu pai e minha irmã que me forneceu todo o suporte necessário, agradeço a minha amada namorada Fernanda Bossolani, por todo o incentivo, cobrança e paciência, agradeço ao meu professor orientador Renan Guilherme Nespolo por sempre me apoiar, incentivar e fornecer todos os ensinamentos necessários.

Com o apoio dessas pessoas que sempre vão estar em meu coração consegui finalizar meu trabalho de conclusão de curso e me formar no curso de Big Data no Agronegócio.

JOSÉ LUCAS GOMES

**PREVISÃO DE MEDIDA DE PESO EM BOVINOS POR  
IMAGENS UTILIZANDO REDES NEURAIAS  
CONVOLUCIONAIS**

Monografia apresentada à Faculdade de Tecnologia de Bebedouro, como parte dos requisitos para a obtenção do título de Tecnólogo em Big Data no Agronegócio

Orientador: **prof. Me. Renan Guilherme Nespolo**

BEBEDOURO

2024

GOMES, J. L. **Previsão de Medida de Peso em Bovinos por Imagens utilizando Redes Neurais Convolucionais**. Trabalho de Graduação (Monografia). Centro Estadual de Educação Tecnológica “Paula Souza”. Faculdade de Tecnologia de Bebedouro. 45 p. 2024.

## RESUMO

O presente estudo apresenta uma proposta para realizar a previsão de medidas de peso em bovinos por meio de técnicas de aprendizado de máquina utilizando imagens. A pesagem de bovinos é crucial para otimizar a produção e garantir o bem-estar animal, mas o método tradicional pode causar estresse nos mesmos. O objetivo deste trabalho é desenvolver um modelo baseado em redes neurais profundas para estimar o peso dos bovinos através da análise de imagens, minimizando a necessidade de manejo direto. As principais contribuições incluem a proposta de um modelo de redes profundas, a comparação de diferentes filtros de imagens (RGB e Tons de Cinza) e a análise de diferentes perspectivas do gado (lateral e frontal). Os resultados esperados buscam validar a eficiência do modelo proposto e contribuir para práticas mais sustentáveis e eficientes na pecuária.

**Palavras-chave:** Bovinos. Redes Neurais. Pesagem. *Dataset*.

GOMES, J. L. **Previsão de Medida de Peso em Bovinos por Imagens utilizando Redes Neurais Convolucionais**. Trabalho de Graduação (Monografia). Centro Estadual de Educação Tecnológica “Paula Souza”. Faculdade de Tecnologia de Bebedouro. 45 p. 2024.

## ABSTRACT

*This present study presents a proposal to carry out the predicting cattle weight measurements using machine learning techniques with images. Weighing cattle is crucial to optimize production and ensure animal welfare, but traditional methods can cause stress. The aim of this work is to develop a model based on deep neural networks to estimate cattle weight through image analysis, minimizing the need for direct handling. The main contributions include the proposal of a deep neural network model, the comparison of different image filters (RGB and Grayscale), and the analysis of different cattle perspectives (side and front). The expected results aim to validate the efficiency of the proposed model and contribute to more sustainable and efficient practices in livestock farming.*

**Keywords:** *Cattle. Neural Networks. Weighing. Dataset.*

## SUMÁRIO

1	INTRODUÇÃO .....	14
2	FUNDAMENTAÇÃO TEÓRICA.....	15
2.1	STRESS ANIMAL.....	15
2.2	TIPOS DE ALIMENTAÇÃO EM BOVINOS.....	16
2.2.1	NECESSIDADE DE TROCA DE DIETA.....	16
2.3	IMPORTÂNCIA DA PESAGEM NA PRODUÇÃO DE BOVINOS.....	17
2.4	REDES NEURAI PROFUNDAS .....	18
2.4.1	MAX POOLING EM CNNs .....	19
2.4.2	DROPOUT EM REDES NEURAI .....	20
2.4.3	FUNÇÃO RELU ( <i>RECTIFIED LINEAR UNIT</i> ).....	20
2.4.4	OTIMIZADOR ADAM ( <i>ADAPTIVE MOMENT ESTIMATION</i> ).....	21
2.4.5	MAE ( <i>MEAN ABSOLUTE ERROR</i> ).....	21
2.4.6	VALIDAÇÃO CRUZADA <i>K-FOLD</i> ( <i>K-FOLD CROSS-VALIDATION</i> ).....	22
2.4.7	<i>IMAGEDATAGENERATOR</i> .....	23
3	MATERIAIS E MÉTODOS .....	25
3.1	CONJUNTO DE DADOS .....	25
3.2	PRÉ-PROCESSAMENTO.....	31
3.3	REDE NEURAL CONVOLUCIONAL .....	32
4	RESULTADOS ESPERADOS.....	36
5	CONCLUSÃO .....	43
	REFERÊNCIAS.....	44

## LISTA DE FIGURAS

<b>Figura 1 - Exemplo de imagem que compõe o Dataset B2 images, com o animal na posição lateral.....</b>	<b>26</b>
<b>Figura 2 - Exemplo de silhueta que compõe o Dataset B2 annotation, com o animal na posição lateral com o tratamento de silhueta RGB, realizado pelo autor do Dataset. ....</b>	<b>26</b>
<b>Figura 3 - Exemplo de imagem que compõe o Dataset B2 images, com o animal na posição frontal. ....</b>	<b>27</b>
<b>Figura 4 - Exemplo de silhueta que compõe o Dataset B2 annotation, com o animal na posição frontal com o tratamento de extração de silhueta RGB, realizado pelo autor do Dataset. ....</b>	<b>27</b>
<b>Figura 5 - Exemplo de imagem que compõe o Dataset B3 images, com o animal na posição lateral.....</b>	<b>28</b>
<b>Figura 6 - Exemplo de silhueta que compõe o Dataset B3 annotation, com o animal na posição lateral com o tratamento realizado pelo autor do Dataset. ....</b>	<b>28</b>
<b>Figura 7 - Exemplo de imagem que compõe o Dataset B4 images, com o animal na posição lateral.....</b>	<b>29</b>
<b>Figura 8 - Exemplo de silhueta que compõe o Dataset B4 annotation, com o animal na posição lateral com o tratamento realizado pelo autor do Dataset. ....</b>	<b>29</b>
<b>Figura 9 - Exemplo de imagem que compõe o Dataset B4 images, com o animal na posição frontal. ....</b>	<b>30</b>
<b>Figura 10 - Exemplo de silhueta que compõe o Dataset B4 annotation, com o animal na posição frontal com o tratamento realizado pelo autor do Dataset.....</b>	<b>30</b>
<b>Figura 11 - Exemplo de imagem processada (em tamanho real 64x64p) do Dataset B2 com tratamento em Tons de Cinza. O animal está na posição lateral em (a) e na posição frontal em (b).....</b>	<b>32</b>
<b>Figura 12 - imagem processada (em tamanho real 64x64p) do Dataset B3 com tratamento em Tons de Cinza, com o animal na posição lateral. ....</b>	<b>32</b>
<b>Figura 13 - Exemplo de imagem processada (em tamanho real 64x64p) do Dataset B4 com tratamento em Tons de Cinza. O animal está na posição lateral em (a) e na posição traseira em (b).....</b>	<b>32</b>

<b>Figura 14 - Exemplo de imagem processada (em tamanho real 64x64p) do Dataset B2 com tratamento RGB, mantendo apenas o canal 'G' ([0,255,0]). O animal está na posição lateral em (a) e na posição frontal em (b).....</b>	<b>33</b>
<b>Figura 15 - Exemplo de imagem processada (em tamanho real 64x64p) do Dataset B3 com tratamento RGB, mantendo apenas o canal 'G' ([0,255,0]), com o animal na posição lateral.....</b>	<b>33</b>
<b>Figura 16 - Exemplo de imagem processada (em tamanho real) do Dataset B4 com tratamento RGB, mantendo apenas o canal 'G' ([0,255,0]). O animal está na posição lateral em (a) e na posição frontal em (b).....</b>	<b>33</b>
<b>Figura 17 - Etapas do algoritmo representado em fluxograma.....</b>	<b>35</b>
<b>Figura 18 - Ilustração da rede neural convolucional e suas camadas. ....</b>	<b>35</b>

## LISTA DE TABELAS

<b>Tabela 1 - Etapas do pré-processamento das imagens utilizado no presente estudo.....</b>	<b>31</b>
<b>Tabela 2 – Arquitetura da CNN proposta para o presente estudo.....</b>	<b>34</b>
<b>Tabela 3 - 10-Fold-Validation do Dataset annotation B2 utilizando o tratamento G com o animal na posição frontal.....</b>	<b>36</b>
<b>Tabela 4 - 10-Fold-Validation do Dataset B2 utilizando as imagens com o tratamento Tons de Cinza com o animal na posição frontal.....</b>	<b>37</b>
<b>Tabela 5 - 10-Fold-Validation do Dataset annotation B2 utilizando nas imagens de silhueta o tratamento G com o animal na posição lateral. ....</b>	<b>37</b>
<b>Tabela 6 - 10-Fold-Validation do Dataset images B2 utilizando nas imagens de treinamento o tratamento Tons de Cinza com o animal na posição lateral.....</b>	<b>37</b>
<b>Tabela 7 - 10-Fold-Validation do Dataset annotation B3 utilizando nas imagens de silhueta o tratamento de silhueta R com o animal na posição lateral. ....</b>	<b>38</b>
<b>Tabela 8 - 10-Fold-Validation do Dataset images B3 utilizando nas imagens do animal o tratamento Tons de Cinza com o animal na posição lateral.....</b>	<b>38</b>
<b>Tabela 9 - 10-Fold-Validation do Dataset annotation B4 utilizando nas imagens de silhueta o tratamento R com o animal na posição frontal.....</b>	<b>39</b>
<b>Tabela 8 - 10-Fold-Validation do Dataset images B4 utilizando nas imagens o tratamento Tons de Cinza com o animal na posição frontal. ....</b>	<b>39</b>
<b>Tabela 11 - 10-Fold-Validation do Dataset annotation B4 utilizando nas imagens de silhueta, o tratamento R com o animal na posição lateral.....</b>	<b>40</b>
<b>Tabela 12 - 10-Fold-Validation do Dataset images B4 utilizando o tratamento Tons de Cinza com o animal na posição lateral.....</b>	<b>40</b>

## LISTA DE GRÁFICOS

<b>Gráfico 1 - Média dos resultados obtidos por meio da técnica 10-Fold-Validation utilizando a métrica MAE normalizada de [0,1].....</b>	<b>41</b>
<b>Gráfico 2 - Resultados obtidos por meio da técnica 10-Fold-Validation utilizando a métrica MAE em quilogramas. ....</b>	<b>41</b>
<b>Gráfico 3 - Média dos resultados obtidos por meio da técnica 10-Fold-Validation utilizando a métrica MAE normalizada de [0,1].....</b>	<b>42</b>
<b>Gráfico 4 - Erros em quilogramas obtidos por meio da técnica 10-Fold-Validation utilizando a métrica MAE em quilogramas. ....</b>	<b>42</b>

## LISTA DE ABREVIATURAS E SIGLAS

MAE	<i>Mean Absolute Error</i> (Erro Médio Absoluto).
ReLU	<i>Rectified Linear Unit</i> (Função de Ativação ReLU).
CNN	<i>Convolutional Neural Networks</i> (Redes Neurais Convolucionais).
Adam	<i>Adaptive Moment Estimation</i> (Otimização Estocástica Adam).
k-Fold	<i>k-Fold Cross-Validation</i> (Validação Cruzada k-fold).
RGB	<i>Red, Green, Blue</i> (Vermelho, Verde, Azul).
SGD	<i>Stochastic Gradient Descent</i> (Gradiente Descendente Estocástico).
MLP	<i>Multilayer Perceptron</i> (Perceptron Multicamadas).
RMSprop	<i>Root Mean Square Propagation</i> (Propagação da Média Quadrática).
SARA	Acidose Ruminal Subaguda.
pH	Potencial Hidrogeniônico.
MSE	<i>Mean Squared Error</i> (Erro Médio Quadrático).
PIL	<i>Python Imaging Library</i> (Biblioteca de Imagens Python).
GS	Gray Scale (Escala de Cinza)

## 1 INTRODUÇÃO

Atualmente no mercado da pecuária é de suma importância saber o peso atual dos animais, visto que a negociação deles geralmente é feita em cima do seu peso, além disso o peso do animal é um fator muito importante para se definir o seu desempenho dentro de uma produção agropecuária, assim como para fatores de nutrição, tais como troca de dieta e para se definir a quantidade diária ideal de ração fornecida que o bovino necessita para ter desempenho e dar resultados.

A pecuária é uma atividade que demanda de muita mão de obra para ser realizada de forma lucrativa, essa mão de obra pode vir em várias etapas da produção, porém a maior parte dela é no manejo direto com os animais. A pesagem dos bovinos é uma atividade muito estressante para os animais, devido ao fato de eles serem levados para outro local e terem que passar dentro da balança, logo é de extrema importância buscar métodos para realizar a pesagem dos animais necessitando de pouco manejo. Porém, com os avanços tecnológicos no campo de aprendizado de máquinas é possível estimar o peso do animal analisando imagens, sem a necessidade de deslocar o animal evitando colocar sob *stress*.

Deste modo, os objetivos do presente estudo buscam construir um modelo que realize a estimativa do peso por análise de imagens de forma digital e instantânea, utilizando o aprendizado de máquina para realizar essa tarefa. As principais contribuições do presente trabalho são:

- Propor um modelo de redes profundas para estimar o peso do gado;
- Comparar diferentes filtros de imagens para estimar o peso (RBG e Tons de Cinza);
- Comparar diferentes perspectivas dos bovinos (Lado x Frente).

O presente trabalho está segmentado em: 1 Introdução; 2 Fundamentação Teórica; Materiais e Métodos; 4 Resultados Esperados; 5 Conclusões; ao final as Referências.

## 2 FUNDAMENTAÇÃO TEÓRICA

Na presente sessão é apresentado os conceitos fundamentais para a realização do estudo divididos em 2.1 *Stress* Animal, 2.2 Perfil de Alimentação Animal, 2.3 Importância da Pesagem na Produção de Bovinos e 2.4 Redes Neurais Profundas.

### 2.1 *STRESS* ANIMAL

É amplamente reconhecido que os animais devem atender às suas necessidades fundamentais (físicas, comportamentais e psicológicas) para sobreviver em ambientes desconhecidos ou em constante mudança (SANTOS, 2005). A capacidade de interação e a resposta individual são os principais determinantes da adaptação e sobrevivência de cada animal ao seu meio ambiente (SANTOS, 2005; ROSA, 2003). Mudanças no ambiente ou no organismo animal podem perturbar o equilíbrio basal, e diferentes espécies têm estratégias únicas para lidar com ou mitigar essas mudanças em suas vidas (SANTOS, 2005; ROSA, 2003).

No entanto, os danos do estresse no organismo animal são amplamente reconhecidos, afetando aspectos comportamentais, reprodutivos, psicológicos e produtivos (ORSINI, 2006; SANTOS, 2005). O estresse pode ser descrito como um estado que antecede ou surge em resposta a uma ameaça ao equilíbrio do organismo, buscando restaurar esse equilíbrio por meio de uma série de respostas fisiológicas e comportamentais (ZUARDI, 2015; ORSINI; FERNANDES, 2006). A manutenção desse equilíbrio, conhecido como homeostase, é essencial para a sobrevivência e é influenciada por fatores tanto internos quanto externos. Qualquer desafio que perturbe esse estado é considerado um estímulo estressante, e todas as reações para lidar com tais perturbações, independentemente de serem benéficas ou não, são denominadas respostas ao estresse (ACCO; PACHALY; BACILA, 1999; ZUARDI, 2015).

## **2.2 TIPOS DE ALIMENTAÇÃO EM BOVINOS**

A nutrição é um dos pilares fundamentais do sistema de produção de bovinos de corte, juntamente com a genética e a saúde animal. O aumento da produtividade de carne e leite emerge como uma alternativa para incrementar a produção sem a necessidade de expandir ou abrir novas áreas para pastagens.

Diferentemente dos outros nutrientes, a energia não se manifesta como uma entidade física no alimento, cuja quantidade disponível para os animais possa ser determinada por meio de análises laboratoriais. A energia é, na verdade, uma propriedade intrínseca do alimento relacionada ao seu potencial de gerar trabalho.

A dieta dos bovinos de corte em confinamento é composta por uma combinação de volumosos e concentrados. Entre os principais volumosos utilizados estão a silagem de milho, a silagem de cana-de-açúcar, a cana-de-açúcar fresca picada e a silagem de capim. (SENAR, 2018).

### **2.2.1 NECESSIDADE DE TROCA DE DIETA**

É reconhecido que a cada alteração na dieta, inclusive na composição dos ingredientes, é necessário um período de adaptação (geralmente de 15 a 20 dias) para que o rúmen, e consequentemente a população bacteriana, se ajuste ao novo perfil nutricional. Cada alimento apresenta um tipo específico de bactéria responsável por sua digestão. Durante esse processo de adaptação, é comum que o animal experimente uma leve acidose ruminal ou SARA (Acidose Ruminal Subaguda), resultando em prejuízos econômicos estimados em US\$1,12 por vaca por dia devido a perdas na produção de leite, nos sólidos e na saúde do rebanho (FERREIRA, 2020).

A inclusão de concentrados na alimentação de bovinos em confinamento é uma resposta à intensificação dos sistemas de produção, visando principalmente aumentar a energia na dieta. Uma das etapas mais críticas do confinamento é o seu início, pois a adaptação ocorre em várias frentes. Desde a aclimação dos animais ao ambiente até as interações sociais, a nova dieta tem um impacto direto no desempenho durante o período de alimentação no cocho. Para animais que estavam a pasto, a transição para uma dieta de alta densidade energética não pode ser feita de forma abrupta (FERREIRA, 2020).

Diante disso, é crucial que esses animais respondam de maneira adequada à nova dieta, considerando suas necessidades fisiológicas. Surge então a necessidade de estabelecer um

protocolo de adaptação para o confinamento de bovinos. No Brasil, em 2019, 83,3% dos pecuaristas incorporavam concentrados na dieta, ainda distantes dos Estados Unidos, onde aproximadamente 91% utilizam essa prática. Conseqüentemente, ao longo dos anos, tem-se observado uma maior inclusão de concentrados no confinamento, o que intensifica o desafio de manter o equilíbrio entre os microrganismos ruminais e o pH adequado no rúmen. (MEDEIROS; GOMES; BUNGENSTAB, 2015).

Embora os ruminantes possuam a capacidade de digerir fibras, a inclusão de concentrados na dieta certamente oferece diversas vantagens aos animais, como um melhor desempenho, ganho de peso e desenvolvimento para aqueles confinados. Os protocolos de alimentação variam de acordo com o tipo de confinamento de bovinos, e alguns dos mais conhecidos são: restrição; dieta com menor teor energético; escada; restrição; e mistura de duas rações. No entanto, além da seleção do protocolo adequado, ressaltamos a importância do controle do consumo, pois sem ele, a adaptação pode levar mais tempo. (MEDEIROS; GOMES; BUNGENSTAB, 2015).

### **2.3 IMPORTÂNCIA DA PESAGEM NA PRODUÇÃO DE BOVINOS**

A pesagem é um aspecto fundamental na produção de bovinos, pois fornece informações cruciais sobre o desenvolvimento e o desempenho dos animais ao longo do tempo. Por meio da pesagem regular, os produtores podem monitorar o ganho de peso dos bovinos, o que é essencial para avaliar a eficácia da dieta e a saúde geral do rebanho. Esses dados permitem ajustes precisos na alimentação e na gestão do manejo, garantindo que os animais atinjam seu potencial genético máximo de crescimento e produção.

Além disso, a pesagem é vital para o planejamento estratégico da produção pecuária. Com informações precisas sobre o peso dos animais, os produtores podem tomar decisões fundamentadas em relação ao momento ideal para a venda, identificando os bovinos que alcançaram o peso de abate desejado. Isso ajuda a otimizar os lucros e a maximizar a eficiência da produção, evitando a permanência desnecessária dos animais no sistema de produção (ORSINI, 2006; SANTOS, 2005).

Por fim, a pesagem regular dos bovinos também desempenha um papel crucial na detecção precoce de problemas de saúde e no monitoramento do bem-estar animal. Variações significativas no peso podem indicar problemas de saúde, como doenças ou parasitas, permitindo intervenções oportunas para garantir o tratamento adequado e minimizar perdas na

produção. Assim, a pesagem não apenas contribui para a eficiência produtiva, mas também para o cuidado responsável e sustentável dos animais na produção de bovinos.

## **2.4 REDES NEURAI PROFUNDAS**

De acordo com Haykin (2001), a teoria das redes neurais surge da necessidade de criar sistemas que possam operar de forma semelhante ao cérebro humano. O cérebro é uma estrutura altamente complexa, não linear e um tipo de computador paralelo, capaz de manipular seus elementos estruturais e realizar certos cálculos mais rapidamente do que qualquer computador digital conhecido. Dessa forma, as redes neurais funcionam por meio de treinamento, em oposição à programação algorítmica.

Devido às suas características únicas, como não linearidade, capacidade de generalização, adaptabilidade e capacidade de mapeamento de saída, as redes neurais encontram aplicação em uma ampla gama de campos, incluindo engenharia, matemática, física, biologia e medicina, entre outros. Essas redes são, portanto, inspiradas no sistema nervoso humano.

Haykin (2001) enfatiza que o elemento fundamental de uma rede neural é o neurônio, que é uma unidade essencial de processamento de informação para o funcionamento da rede neural. Esses neurônios consistem em nós de entrada, sinapses, um somador, um termo de polarização e uma função de ativação.

As Redes Neurais Convolucionais (CNNs), do inglês Convolutional Neural Networks, têm desempenhado um papel significativo na aplicação de tecnologias de inteligência artificial na produção de bovinos. As CNNs são uma classe especializada de redes neurais profundas projetadas para processar e analisar dados de forma eficiente, especialmente em tarefas relacionadas à visão computacional.

Na pecuária, as CNNs podem ser aplicadas em diversas áreas, como na identificação e classificação de características físicas dos bovinos, como raça, idade e condição de saúde. Por exemplo, utilizando imagens de câmeras de monitoramento, as CNNs podem ser treinadas para identificar automaticamente anomalias físicas nos animais, como lesões ou doenças visíveis.

Além disso, as CNNs também podem ser empregadas na análise de comportamento animal, como a detecção de padrões de movimento ou interações sociais entre os bovinos. Isso pode auxiliar os produtores na identificação de comportamentos anormais que possam indicar estresse, desconforto ou problemas de bem-estar animal.

Outra aplicação potencial das CNNs na produção de bovinos é na monitorização da ingestão de alimentos e na avaliação da eficácia da alimentação. Por exemplo, sistemas de visão computacional podem ser integrados aos cochos de alimentação para rastrear e analisar os padrões de consumo alimentar dos bovinos ao longo do tempo, fornecendo insights valiosos para a otimização da dieta e do manejo alimentar.

Em resumo, as Redes Neurais Convolucionais representam uma poderosa ferramenta para a análise de dados na produção de bovinos, oferecendo novas perspectivas e possibilidades para a melhoria da eficiência, saúde e bem-estar do rebanho.

#### **2.4.1 MAX POOLING EM CNNS**

Além das camadas convolucionais discutidas nas seções anteriores, as redes neurais convolucionais também incluem camadas de agrupamento, conhecidas como camadas de Pooling.

Essas camadas são comumente posicionadas logo após as camadas convolucionais e têm a função de simplificar as informações produzidas na saída dessas camadas. Uma camada de pooling recebe cada saída do mapa de características da camada convolucional e produz um mapa de características condensadas.

O *Max-Pooling* é uma técnica onde a rede verifica se um determinado recurso está presente em qualquer lugar de uma região da imagem, e então elimina a informação de posição exata. A ideia por trás disso é que, uma vez que um recurso tenha sido identificado, sua localização precisa não é tão relevante quanto sua posição geral em relação a outros recursos. Um benefício significativo é a redução do número de recursos agrupados, o que, por sua vez, ajuda a diminuir a quantidade de parâmetros necessários nas camadas subsequentes (DSA, 2020). No entanto, é importante notar que o *Max-Pooling* não é a única técnica utilizada para o agrupamento de informações.

## 2.4.2 DROPOUT EM REDES NEURAIAS

O *Dropout* é uma técnica popular de regularização usada em redes neurais profundas para evitar o sobre ajuste (*overfitting*) durante o treinamento do modelo. No entanto, seu uso direto em bovinos pode ser desafiador devido à natureza dos dados e ao contexto da aplicação.

Em aplicações tradicionais de aprendizado de máquina, o *Dropout* funciona desativando aleatoriamente um número definido de neurônios durante o treinamento, o que impede que os neurônios se coadaptem em excesso e tornem o modelo muito sensível aos dados de treinamento específicos. Isso geralmente melhora a capacidade de generalização do modelo para novos dados. (BERNARDO, 2018).

No entanto, aplicar o *Dropout* diretamente em bovinos envolve questões práticas significativas. Por exemplo, não é viável desativar aleatoriamente partes do comportamento dos animais durante a coleta de dados. Além disso, a natureza dos dados relacionados à produção de bovinos, como pesos, características físicas e dados de saúde, pode não se encaixar bem com a técnica de *Dropout*.

Em vez disso, abordagens alternativas de regularização e técnicas de controle de sobre ajuste podem ser mais adequadas para aplicação em bovinos. Isso pode incluir a coleta cuidadosa de dados representativos, a seleção adequada de recursos e a escolha de arquiteturas de modelo que sejam menos propensas ao sobre ajuste, juntamente com técnicas de validação cruzada e ajuste de hiper parâmetros.

Em resumo, embora o *Dropout* seja uma técnica valiosa em muitos contextos de aprendizado de máquina, sua aplicação direta em bovinos pode ser desafiadora e exigir abordagens alternativas de regularização e controle de sobre ajuste. (BERNARDO, 2018).

## 2.4.3 FUNÇÃO RELU (*RECTIFIED LINEAR UNIT*)

A função ReLU (*Rectified Linear Unit*) é uma função de ativação amplamente utilizada em redes neurais, incluindo aquelas aplicadas na produção de bovinos. Esta função é definida como  $f(x) = \max(0, x)$ , o que significa que ela retorna o valor de entrada se for positivo e zero caso contrário. (ESTEVES, 2022)

A função ReLU é preferida em muitas redes neurais devido à sua simplicidade e eficácia. Ela introduz não linearidades nas camadas da rede, permitindo que o modelo aprenda relações complexas nos dados. Além disso, a função ReLU tende a acelerar o treinamento de

redes neurais, uma vez que é computacionalmente eficiente e não sofre do problema de "desvanecimento do gradiente" como algumas funções de ativação, como a sigmoide e a tangente hiperbólica.

Na produção de bovinos, a função ReLU pode ser aplicada em várias etapas do processamento de dados, como na camada de entrada para normalizar os dados, nas camadas ocultas para introduzir não linearidades e nos neurônios de saída para gerar previsões ou classificações. Ela ajuda a capturar padrões complexos nos dados relacionados à produção de bovinos, como características físicas dos animais, dados de alimentação e saúde, e comportamento animal.

Em suma, a função ReLU é uma ferramenta valiosa em redes neurais aplicadas à produção de bovinos, ajudando a melhorar a eficácia e a eficiência dos modelos, permitindo a aprendizagem de representações mais úteis e complexas dos dados.

#### **2.4.4 OTIMIZADOR ADAM (*ADAPTIVE MOMENT ESTIMATION*)**

Adam (derivado de *Adaptive Moment Estimation*) é um algoritmo de otimização que pode ser utilizado no lugar do procedimento clássico de descida de gradiente estocástico para atualizar os pesos da rede com base nos dados de treinamento. Este algoritmo calcula taxas de aprendizagem adaptativas individuais para diferentes parâmetros, baseando-se nas estimativas dos gradientes. O Adam combina aspectos do AdaGrad, ao ajustar a taxa de aprendizagem de acordo com a mudança nos parâmetros, e do RMSProp, ao calcular uma média móvel exponencial tanto do gradiente quanto do gradiente quadrado. Isso torna o Adam um algoritmo bastante poderoso e rápido (LIU et al., 2023).

#### **2.4.5 MAE (*MEAN ABSOLUTE ERROR*)**

A métrica MAE (*Mean Absolute Error*, ou Erro Médio Absoluto) é uma medida estatística que quantifica a média das diferenças absolutas entre os valores preditos por um modelo e os valores reais observados. Após o desenvolvimento do modelo, o MAE é usado para avaliar a precisão das previsões. O MAE é calculado pela média das diferenças absolutas entre os valores preditos pelo modelo e os valores reais observados nos dados de validação ou teste. O MAE fornece uma medida fácil de interpretar da precisão do modelo, expressa nas mesmas unidades dos dados de entrada. Embora menos sensível a outliers em comparação com métricas como o MSE (*Mean Squared Error*), o MAE ainda captura as variações nos erros de

previsão de maneira intuitiva. Utilizar o MAE como métrica de avaliação ajuda os pesquisadores a entender a performance do modelo e identificar áreas onde as previsões podem ser melhoradas. Em resumo, a métrica MAE é crucial para avaliar e aprimorar modelos preditivos no estudo do estresse animal, contribuindo para um melhor entendimento e gestão do bem-estar dos animais (BARTH, 2023).

#### **2.4.6 Validação cruzada *k-Fold* (*k-Fold Cross-Validation*)**

A maioria dos algoritmos de aprendizado de máquina possui hiper parâmetros, que são configurações usadas para controlar o comportamento do algoritmo. Os valores desses hiper parâmetros não são ajustados pelo próprio algoritmo de aprendizagem. Às vezes, uma configuração é escolhida como hiper parâmetro porque a otimização necessária é complexa demais para o algoritmo aprender sozinho (MURPHY, 2012). Mais frequentemente, um parâmetro é tratado como hiper parâmetro porque não é adequado aprendê-lo diretamente no conjunto de treinamento. Isso se aplica a todos os hiper parâmetros que controlam a capacidade do modelo. Se fossem aprendidos no conjunto de treinamento, esses hiper parâmetros sempre selecionariam a capacidade máxima possível do modelo, resultando em *overfitting*. Para evitar esse problema, é necessário um conjunto de validação composto por amostras que o algoritmo de treinamento não vê (MURPHY, 2012).

É crucial que as amostras de teste não sejam usadas de nenhuma maneira para tomar decisões sobre o modelo, incluindo a escolha de hiper parâmetros. Por essa razão, nenhuma amostra do conjunto de teste deve ser incluída no conjunto de validação. Portanto, o conjunto de validação é sempre construído a partir dos dados de treinamento. Especificamente, dividimos os dados de treinamento em dois subconjuntos separados: um usado para aprender os parâmetros (MURPHY, 2012) e o outro como conjunto de validação, que estima o erro de generalização durante ou após o treinamento, permitindo a atualização dos hiper parâmetros conforme necessários (CHARNIAK, 2019).

O subconjunto de dados usado para aprender os parâmetros ainda é normalmente chamado de conjunto de treinamento, embora possa ser confundido com o conjunto maior de dados usado para todo o processo de treinamento. O subconjunto de dados usado para orientar a seleção de hiper parâmetros é chamado de conjunto de validação. Normalmente, usa-se cerca de 80% dos dados de treinamento para o treinamento em si e 20% para validação. Após a

conclusão da otimização dos hiper parâmetros, o erro de generalização pode ser estimado usando o conjunto de teste (MURPHY, 2012).

Dividir o *Dataset* em um conjunto de treinamento fixo e um conjunto de teste fixo pode ser problemático se resultar em um conjunto de teste pequeno. Um conjunto de teste pequeno implica em incerteza estatística em torno do erro de teste médio estimado, dificultando a afirmação de que o algoritmo A é melhor que o algoritmo B para uma tarefa específica. Quando o *Dataset* possui centenas de milhares de exemplos ou mais, esse não é um problema sério. Porém, quando o *Dataset* é muito pequeno, procedimentos alternativos permitem usar todos os dados na estimativa do erro médio de teste, ao custo de um aumento na demanda computacional (GOODFELLOW; BENGIO; COURVILLE, 2017).

Esses procedimentos são baseados na repetição do treinamento e teste em diferentes subconjuntos ou divisões aleatórias do *Dataset* original. O mais comum é o procedimento de validação cruzada *k-Fold*, no qual o *Dataset* é dividido em *k* subconjuntos não sobrepostos. O erro de teste pode ser estimado tomando-se a média dos erros de teste ao longo das *k* iterações (GOODFELLOW; BENGIO; COURVILLE, 2017).

#### **2.4.7 IMAGEDATAGENERATOR**

O uso do `ImageDataGenerator` para enriquecer o número de exemplos em Redes Neurais Convolucionais (CNNs) é uma técnica essencial para melhorar a performance e a generalização dos modelos de aprendizado de máquina, especialmente quando se trabalha com *Datasets* limitados. O enriquecimento de dados envolve a criação de novas amostras de treinamento a partir das existentes, aplicando várias transformações como rotações, translações, espelhamento, zoom e alterações de brilho (dados sintéticos). O `ImageDataGenerator`, disponível na biblioteca Keras do *TensorFlow*, facilita a aplicação dessas transformações de maneira eficiente e automática durante o treinamento das CNNs. Isso é particularmente útil em aplicações como a detecção de estresse animal, onde pode ser difícil coletar grandes volumes de dados variados e representativos (*Tensorflow.org*).

A técnica de enriquecimento de dados com `ImageDataGenerator` melhora a generalização do modelo, ajudando a evitar *overfitting* e aumentando a capacidade de generalização para novas amostras. Isso é alcançado ao criar múltiplas variações das imagens de treinamento, expondo o modelo a uma maior diversidade de dados. Além disso, aumenta

efetivamente o tamanho do *Dataset* sem a necessidade de coletar mais dados, o que é particularmente vantajoso quando se tem acesso limitado a dados de animais em diferentes condições de estresse. As transformações são aplicadas em tempo real durante o treinamento, sem a necessidade de armazenar um grande número de imagens no disco, o que melhora a eficiência de memória.

No contexto da avaliação do estresse animal, onde dados como imagens ou vídeos de animais são analisados para sinais de estresse, a utilização do `ImageDataGenerator` pode ser extremamente útil. Por exemplo, ao trabalhar com imagens de animais, transformações como rotações, espelhamento, zoom, translações e ajustes de brilho e contraste ajudam a criar um modelo mais robusto às variações na posição dos animais, diferentes escalas, posições e condições de iluminação. Essas técnicas preparam o modelo para operar em condições variadas e detectar características de estresse de maneira mais eficaz.

Um exemplo de configuração do `ImageDataGenerator` pode incluir a aplicação de transformações como rotação, deslocamento, cisalhamento, zoom e espelhamento horizontal, preenchendo as áreas vazias geradas pelas transformações com o método mais próximo. O gerador de dados pode ser usado para carregar imagens de treinamento e treinar o modelo com essas imagens aumentadas, o que aumenta a diversidade do *Dataset* e ajuda o modelo a se tornar mais robusto.

A aplicação dessas técnicas no estudo do estresse animal pode levar a modelos mais precisos e generalizáveis, capazes de detectar sinais de estresse de maneira eficaz e confiável em diferentes condições e contextos.

### 3 MATERIAIS E MÉTODOS

O presente estudo se concentra em inferir a pesagem diária de bovinos por meio de imagens. As imagens para treinamento e inferência do algoritmo foram tiradas com os animais nas posições lateral e traseira, conforme descritos no item 3.1.

#### 3.1 Conjunto de Dados

A aquisição dos dados foi realizada em um estudo recente que se concentrou em inferir a pesagem de bovinos por meio de imagens levando em consideração as medidas do seu comprimento corporal e circunferência torácica (Acme AI Ltd. et al., 2023).

Os conjuntos de dados utilizados contêm um total de 15.000 imagens, distribuídas da seguinte forma:

1. 7.500 imagens reais, das quais:
  - 5.050 imagens mostram o animal na posição lateral;
  - 2.450 imagens mostram o animal na posição frontal.
  
2. 7.500 imagens tratadas no formato RGB para silhueta do animal, sendo:
  - 5.050 imagens com o animal na posição lateral;
  - 2.450 imagens com o animal na posição frontal.

No total, os conjuntos de dados utilizados representam 5.050 animais divididos em 3 *Datasets*:

1. B2, contendo imagens de 510 animais nas posições lateral e frontal.
2. B3, contendo imagens de 2600 animais na posição lateral.
3. B4, contendo imagens de 1940 animais nas posições lateral e frontal.

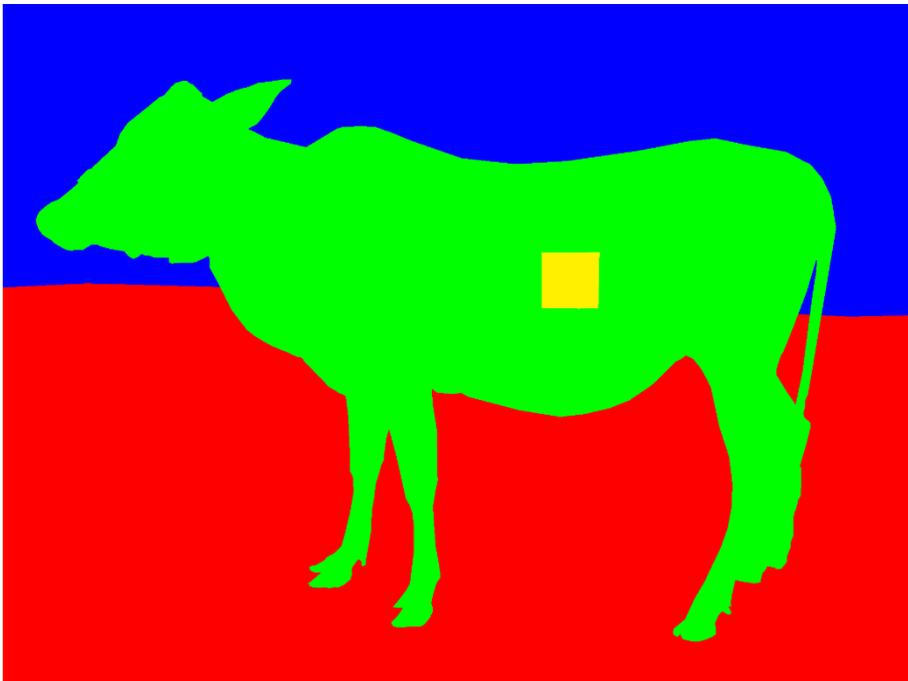
As imagens encontradas nos *Datasets* em sua maioria seguem dois padrões, uma imagem real do animal e outra com um tratamento RGB feito pelo autor do *Dataset* (Acme AI Ltd. et al., 2023), podemos ver alguns exemplo apresentados pelas figuras 1,2,3,4,5,6,7,8,9,10:

**Figura 1 - Exemplo de imagem que compõe o *Dataset B2 images*, com o animal na posição lateral.**



Fonte: (Acme AI Ltd. et al., 2023).

**Figura 2 - Exemplo de silhueta que compõe o *Dataset B2 annotation*, com o animal na posição lateral com o tratamento de silhueta RGB, realizado pelo autor do *Dataset*.**



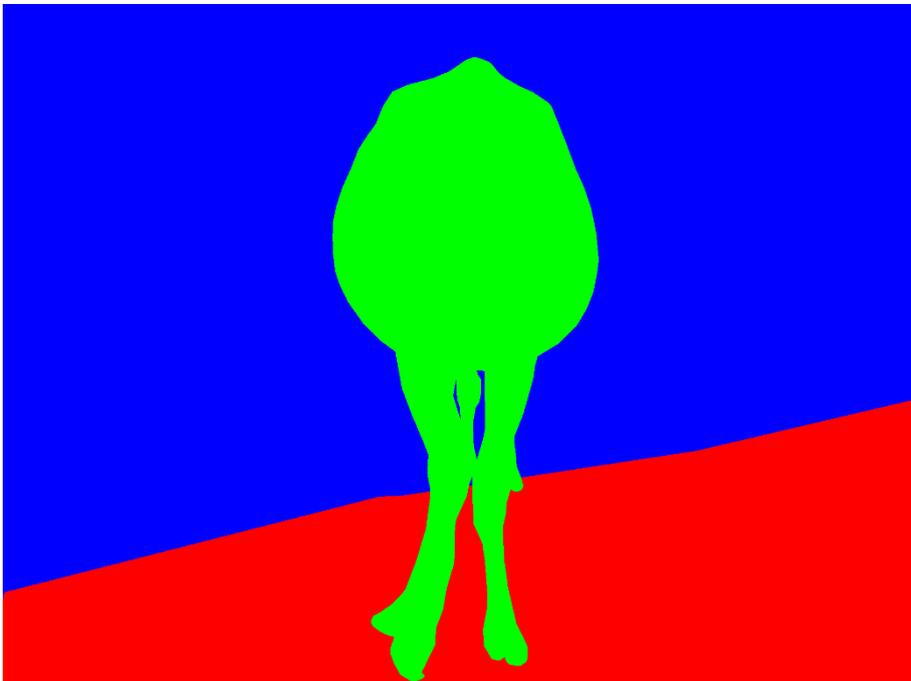
Fonte: (Acme AI Ltd. et al., 2023).

**Figura 3 - Exemplo de imagem que compõe o *Dataset B2 images*, com o animal na posição frontal.**



Fonte: (Acme AI Ltd. et al., 2023).

**Figura 4 - Exemplo de silhueta que compõe o *Dataset B2 annotation*, com o animal na posição frontal com o tratamento de extração de silhueta RGB, realizado pelo autor do *Dataset*.**



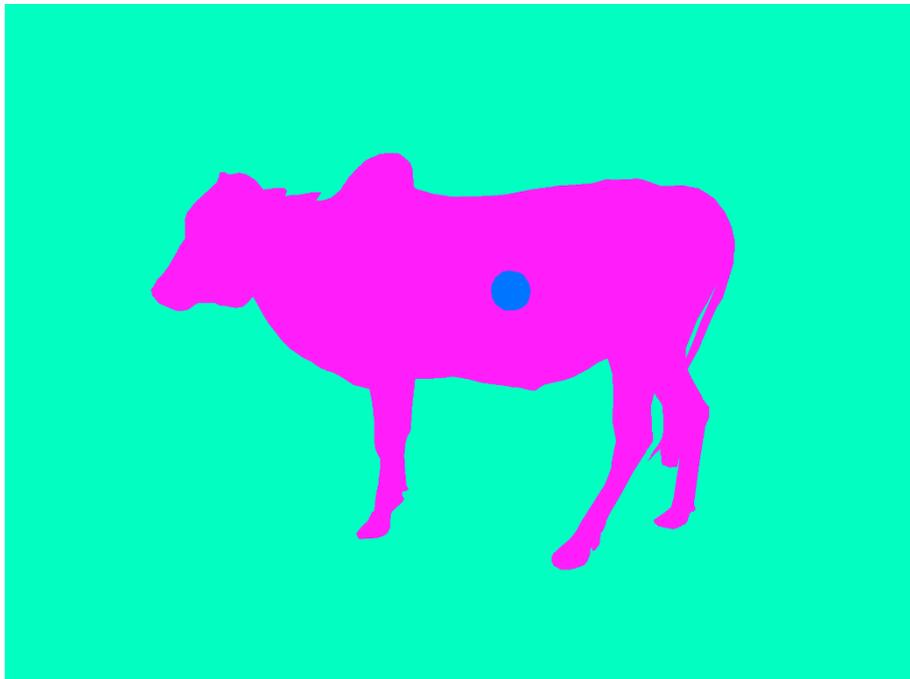
Fonte: (Acme AI Ltd. et al., 2023).

**Figura 5 - Exemplo de imagem que compõe o *Dataset B3 images*, com o animal na posição lateral.**



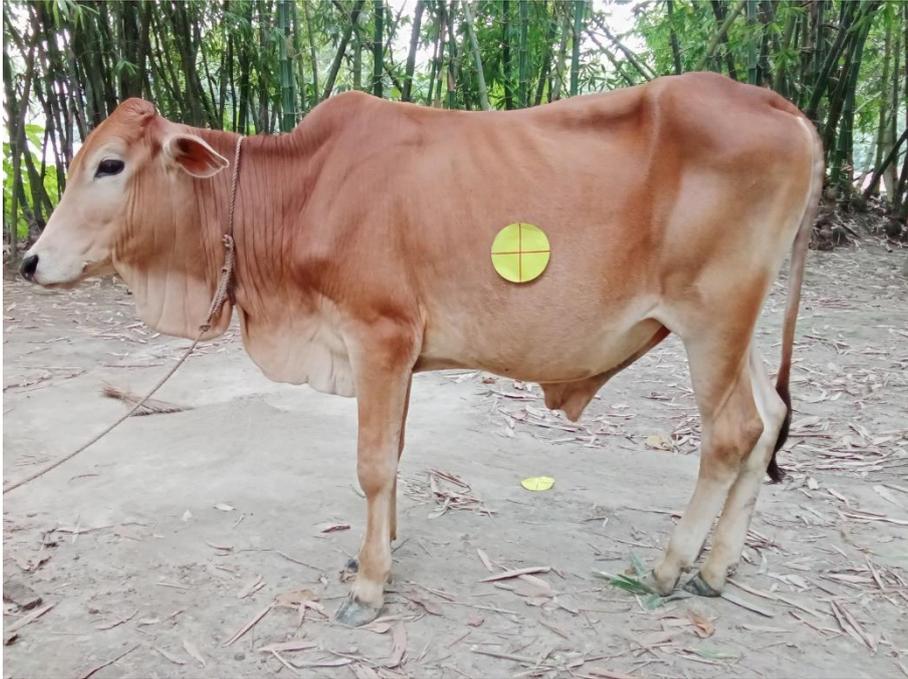
Fonte: (Acme AI Ltd. et al., 2023).

**Figura 6 - Exemplo de silhueta que compõe o *Dataset B3 annotation*, com o animal na posição lateral com o tratamento realizado pelo autor do *Dataset*.**



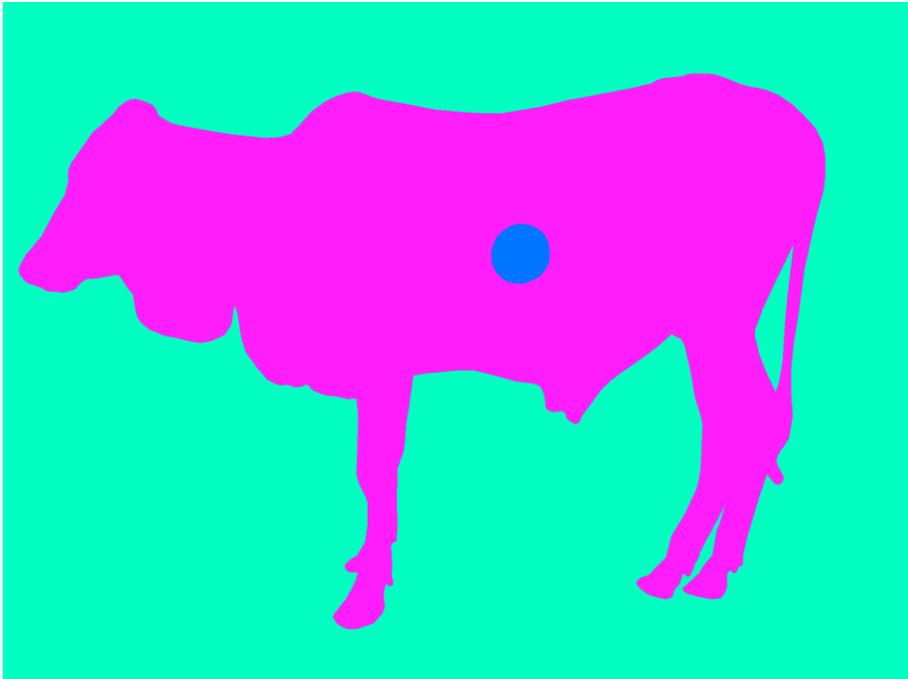
Fonte: (Acme AI Ltd. et al., 2023).

**Figura 7 - Exemplo de imagem que compõe o *Dataset B4 images*, com o animal na posição lateral.**



Fonte: (Acme AI Ltd. et al., 2023).

**Figura 8 - Exemplo de silhueta que compõe o *Dataset B4 annotation*, com o animal na posição lateral com o tratamento realizado pelo autor do *Dataset*.**



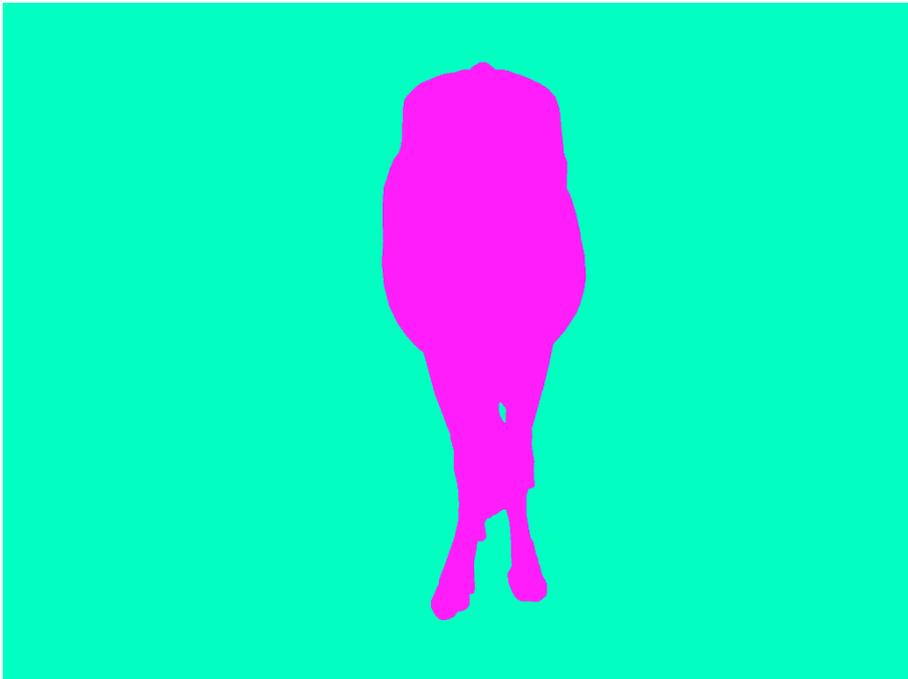
Fonte: (Acme AI Ltd. et al., 2023).

**Figura 9 - Exemplo de imagem que compõe o *Dataset B4 images*, com o animal na posição frontal.**



Fonte: (Acme AI Ltd. et al., 2023).

**Figura 10 - Exemplo de silhueta que compõe o *Dataset B4 annotation*, com o animal na posição frontal com o tratamento realizado pelo autor do *Dataset*.**



Fonte: (Acme AI Ltd. et al., 2023).

É possível notar que as imagens tratadas com filtro de silhueta RGB pelo autor dos *Datasets* ficaram bem fiéis em relação as imagens originais.

Além dos dados adquiridos nos *Datasets* foi utilizado também uma função de criação de dados sintéticos onde os dados são enriquecidos gerando mais exemplos para o treinamento do algoritmo utilizando a função *ImageDataGenerator*, seção 2.4.7.

A estimativa de peso será realizada por meio de uma rede neural convolucional conforme descrita no item 3.2.

### 3.2 Pré-Processamento

O pré-processamento das imagens é uma etapa de extrema importância para garantir que os dados estejam em um formato adequado antes de serem passados para a rede neural convolucional. No caso do presente estudo, o pré-processamento é apresentado na tabela 1:

**Tabela 1 - Etapas do pré-processamento das imagens utilizado no presente estudo.**

Etapas do pré-processamento das imagens.	
1	Utilizamos as bibliotecas <i>numpy</i> , <i>PIL (Python Imaging Library)</i> , os, <i>tensorflow</i> , e <i>tensorflow.keras</i> para manipulação de dados, manipulação de arquivos, e construção e treinamento do modelo de rede neural.
2	Foi definido o tamanho do lote ( <i>batch size</i> ) como 64, o número de épocas ( <i>epochs</i> ) como 200, e as dimensões das imagens como 64x64 pixels ( <i>img_rows = 64</i> e <i>img_cols = 64</i> ).
3	As imagens foram convertidas para o formato RGB no tratamento RGB e em Tons de Cinza para o tratamento Tons de Cinza, então redimensionamos a imagem para 64x64 pixels. Para o tratamento RGB extraímos o canal verde da imagem quando o autor do <i>Dataset</i> configurou a silhueta do animal para verde e vermelho quando a imagem foi tratada para vermelho, já para o Tons de Cinza deixamos como está.
4	As imagens foram convertidas para o tipo <i>float32</i> e normalizamos os valores dos pixels para o intervalo [0, 1] dividindo por 255.
5	Foi configurado o <i>ImageDataGenerator</i> com várias transformações, incluindo: <ul style="list-style-type: none"> <li>• Rotação de até 10 graus (<i>rotation_range=10</i>).</li> <li>• Deslocamento horizontal e vertical de até 10% (<i>width_shift_range=0.1</i>, <i>height_shift_range=0.1</i>).</li> <li>• <i>Flip</i> horizontal (<i>horizontal_flip=True</i>).</li> </ul>

---

 Etapas do pré-processamento das imagens.
 

---

- Zoom de até 20% ( $zoom\_range = 0.2$ ).
- 5
- Transformação *shear* de até 20% ( $shear\_range = 0.2$ ).

E então as imagens estão prontas para seguirem para a rede neural convolucional, como descrita na seção 3.3.

---

Fonte: Elaborado pelo autor.

O processamento das imagens é uma etapa crucial no processo do algoritmo, é o que vai definir se as imagens vão ou não ser aproveitadas ao máximo pela rede neural. Abaixo podemos observar exemplos das imagens processadas prontas para seguir para a rede neural convolucional que após processadas as imagens apresentadas na seção 3.1, são transformadas para a rede neural no tamanho de 64x64 pixels e com filtro de tons de cinzas, como apresentadas as figuras: 11,12,13; ou com só um canal de cor do padrão RGB (vermelho, verde e Azul) como apresentados nas figuras,14,15,16.

**Figura 11 - Exemplo de imagem processada (em tamanho real 64x64p) do Dataset B2 com tratamento em Tons de Cinza. O animal está na posição lateral em (a) e na posição frontal em (b).**



Fonte: Imagem modificada de (Acme AI Ltd. et al., 2023).

**Figura 12 - imagem processada (em tamanho real 64x64p) do Dataset B3 com tratamento em Tons de Cinza, com o animal na posição lateral.**



Fonte: Imagem modificada de (Acme AI Ltd. et al., 2023).

**Figura 13 - Exemplo de imagem processada (em tamanho real 64x64p) do Dataset B4 com tratamento em Tons de Cinza. O animal está na posição lateral em (a) e na posição traseira em (b).**



Fonte: Imagem modificada de (Acme AI Ltd. et al., 2023).

**Figura 14 - Exemplo de imagem processada (em tamanho real 64x64p) do *Dataset B2* com tratamento RGB, mantendo apenas o canal 'G' ([0,255,0]). O animal está na posição lateral em (a) e na posição frontal em (b).**



Fonte: Imagem modificada de (Acme AI Ltd. et al., 2023).

**Figura 15 - Exemplo de imagem processada (em tamanho real 64x64p) do *Dataset B3* com tratamento RGB, mantendo apenas o canal 'G' ([0,255,0]), com o animal na posição lateral.**



Fonte: Imagem modificada de (Acme AI Ltd. et al., 2023).

**Figura 16 - Exemplo de imagem processada (em tamanho real) do *Dataset B4* com tratamento RGB, mantendo apenas o canal 'G' ([0,255,0]). O animal está na posição lateral em (a) e na posição frontal em (b).**



Fonte: Imagem modificada de (Acme AI Ltd. et al., 2023).

### 3.3 Rede Neural Convolutacional

A rede foi implementada na linguagem Python versão 3.12.3, utilizando os pacotes Keras e *TensorFlow*, tais pacotes que fornecem ferramentas poderosas e intuitivas para a construção e treinamento de modelos de aprendizado, foram utilizados também os pacotes NumPy para tratar operações matemáticas e o pacote PIL (Python Imaging Library) para a manipulação de imagens, assim como o pacote os e os.path para facilitar a manipulação de caminhos de arquivos e diretórios.

A arquitetura sequencial proposta para a rede neural convolucional está apresentada na tabela 2:

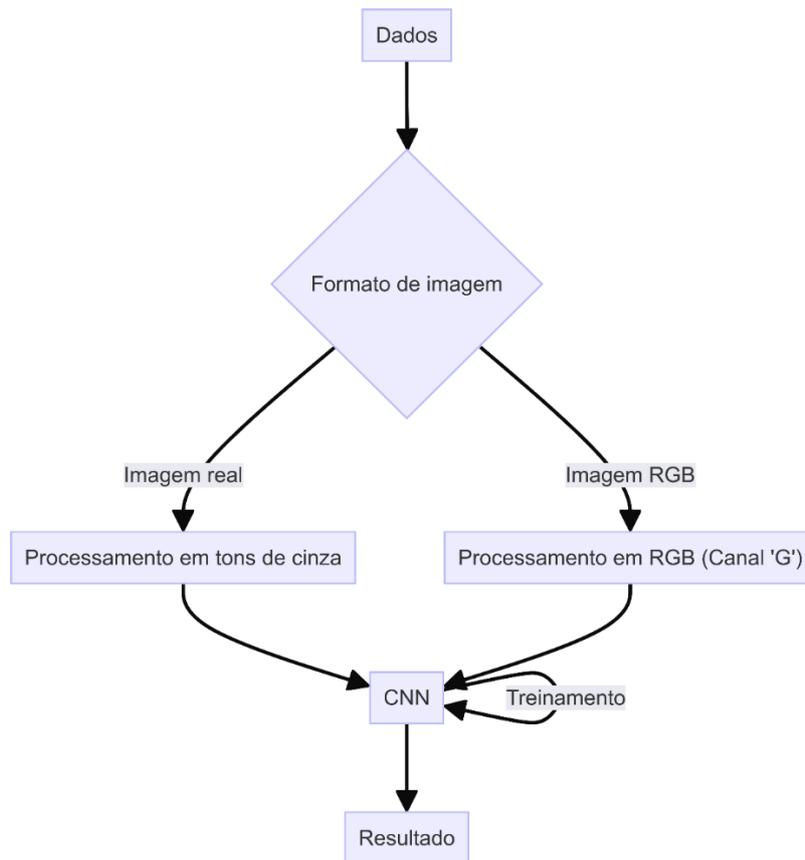
**Tabela 2 – Arquitetura da CNN proposta para o presente estudo.**

Camadas utilizadas na CNN	
1	Camada de Convolução (Conv2D): A primeira camada é uma camada de convolução com 32 filtros, cada um de tamanho 3x3. Ela aplica uma operação de convolução na entrada (que deve ser uma imagem) para extrair características relevantes. A função de ativação usada é a ReLU ( <i>Rectified Linear Unit</i> ), que ajuda a introduzir não-linearidade na rede.
2	Camada de <i>Max-Pooling</i> (MaxPooling2D): Em seguida, temos uma camada de <i>Max-Pooling</i> com um tamanho de pool de 2x2. Essa camada reduz a dimensionalidade da saída da camada de convolução, mantendo as características mais importantes.
3	Outra Camada de Convolução (Conv2D): Depois, adicionamos outra camada de convolução com 64 filtros de tamanho 5x5 e função de ativação ReLU. Essa camada continua a extrair características da imagem.
4	Outra Camada de <i>Max-Pooling</i> (MaxPooling2D): Novamente, aplicamos uma camada de <i>Max-Pooling</i> com um tamanho de pool de 2x2 para reduzir ainda mais a dimensionalidade.
5	Camada de <i>Dropout</i> : A camada de <i>Dropout</i> com uma taxa de 0,25 é usada para evitar <i>overfitting</i> . Ela desativa aleatoriamente 25% das unidades durante o treinamento, o que ajuda a regularizar a rede.
6	Camada de <i>Flattening</i> : A camada de <i>Flattening</i> transforma a saída da camada anterior em um vetor unidimensional, preparando-a para a próxima camada densa.
7	Camada Densa ( <i>Dense</i> ): A camada densa possui 128 neurônios com função de ativação ReLU. Ela é totalmente conectada e aprende padrões mais complexos nas características extraídas pelas camadas anteriores.
8	Outra Camada de <i>Dropout</i> : Mais uma camada de <i>Dropout</i> com taxa de 0,5 é adicionada para regularização.
9	Camada de Saída ( <i>Dense</i> ): A última camada é uma camada densa com apenas 1 neurônio, que representa a saída da rede.

Fonte: Elaborado pelo autor.

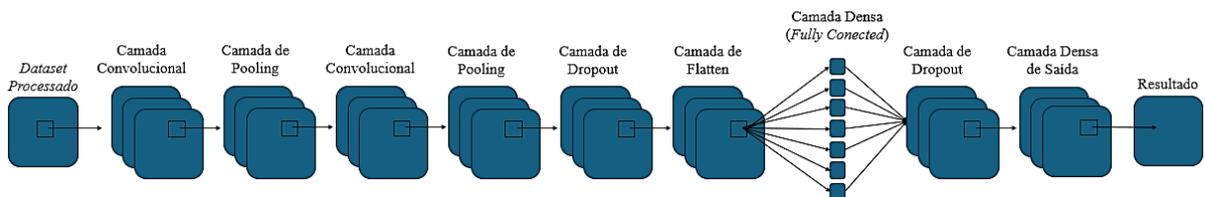
Os resultados obtidos são apresentados na seção 4, utilizando as métricas de erro MAE (Erro Médio Absoluto), descritas na seção 2.4.6, e a validação cruzada *10-Fold*, apresentada na seção 2.4.7. A seguir é apresentado um fluxograma (figura 17) das etapas do presente estudo, enquanto a figura 18 detalha a estrutura da rede neural convolucional utilizada, composta por 9 camadas.

**Figura 17 - Etapas do algoritmo representado em fluxograma.**



Fonte: Elaborado pelo autor.

**Figura 18 - Ilustração da rede neural convolucional e suas camadas.**



Fonte: Elaborado pelo autor.

#### 4 RESULTADOS ESPERADOS

Os conjuntos de dados utilizados para esse estudo foram o B2, B3 e B4, sendo ambos usados no tratamento de silhuetas, filtros RGB (somente uma cor entre as 3: vermelho, verde ou azul) e a imagem original do animal para o tratamento Tons de Cinza (GS) (Acme AI Ltd. et al., 2023). A métrica utilizada sendo a MAE, seção 2.4.5, normalizando os dados de saída entre 0 e 1 assim como seu valor em quilogramas. Todos os experimentos utilizam como validação o *10-Fold-Validation*, apresentando na seção 2.4.6, dividindo o *Dataset* em 10 partes(*folds*), realizando o treinamento com 9 partes e testando em uma parte não vista. Abaixo são apresentados os resultados referentes aos testes para os experimentos utilizando o *Dataset* B2 comparando as imagens (*Dataset images* B2) em Tons de cinza com as silhuetas utilizando o filtro G(somente a cor verde do RGB)(*Dataset annotation* B2) então dois experimentos são realizados, que são a comparação dos resultados entre as imagens frontais (*Dataset images* B2) GS apresentado na tabela 4, com as imagens de silhueta (*Dataset annotation* B2) apresentado na tabela 3; e o segundo experimento foi utilizando as imagens laterais entre as imagens GS do *Dataset images* B2, apresentado na tabela 6, e as imagens de silhueta utilizando o filtro G(Somente a cor verde do RGB) do *Dataset annotation* B2, apresentados na tabela 5.

**Tabela 3 - 10-Fold-Validation do Dataset annotation B2 utilizando o tratamento G com o animal na posição frontal.**

<i>Fold</i>	MAE (Normalizado [0,1])	MAE (Quilogramas)
<i>Fold 1</i>	0,0690	32,2444
<i>Fold 2</i>	0,0988	43,0077
<i>Fold 3</i>	0,0888	40,6324
<i>Fold 4</i>	0,0569	26,8100
<i>Fold 5</i>	0,0740	33,5466
<i>Fold 6</i>	0,0638	27,8559
<i>Fold 7</i>	0,0681	31,5416
<i>Fold 8</i>	0,0620	26,8868
<i>Fold 9</i>	0,0909	40,2175
<i>Fold 10</i>	0,0660	30,4570
<b>Erro médio</b>	<b>0,0738</b>	<b>33,3199</b>

Fonte: Elaborada pelo autor.

**Tabela 4 - 10-Fold-Validation do Dataset B2 utilizando as imagens com o tratamento Tons de Cinza com o animal na posição frontal.**

<i>Fold</i>	MAE (Normalizado [0,1])	MAE (Quilogramas)
<i>Fold 1</i>	0,0779	32,9298
<i>Fold 2</i>	0,1078	44,4866
<i>Fold 3</i>	0,0933	41,7167
<i>Fold 4</i>	0,0643	27,1281
<i>Fold 5</i>	0,0782	33,2189
<i>Fold 6</i>	0,0703	28,1287
<i>Fold 7</i>	0,0798	32,6535
<i>Fold 8</i>	0,0661	28,0849
<i>Fold 9</i>	0,0893	42,3876
<i>Fold 10</i>	0,0749	31,2867
<b>Erro médio</b>	<b>0,0801</b>	<b>34,2021</b>

Fonte: Elaborada pelo autor.

**Tabela 5 - 10-Fold-Validation do Dataset annotation B2 utilizando nas imagens de silhueta o tratamento G com o animal na posição lateral.**

<i>Fold</i>	MAE (Normalizado [0,1])	MAE (Quilogramas)
<i>Fold 1</i>	0,0754	32,1994
<i>Fold 2</i>	0,1097	46,6877
<i>Fold 3</i>	0,0915	40,6341
<i>Fold 4</i>	0,0541	27,6980
<i>Fold 5</i>	0,0744	33,2273
<i>Fold 6</i>	0,0626	26,9776
<i>Fold 7</i>	0,0631	30,1042
<i>Fold 8</i>	0,0576	25,6851
<i>Fold 9</i>	0,0968	43,0049
<i>Fold 10</i>	0,0721	32,2680
<b>Erro médio</b>	<b>0,0757</b>	<b>33,8486</b>

Fonte: Elaborada pelo autor.

**Tabela 6 - 10-Fold-Validation do Dataset images B2 utilizando nas imagens de treinamento o tratamento Tons de Cinza com o animal na posição lateral.**

<i>Fold</i>	MAE (Normalizado [0,1])	MAE (Quilogramas)
<i>Fold 1</i>	0,0751	32,3400
<i>Fold 2</i>	0,1077	44,6294
<i>Fold 3</i>	0,1004	42,8447
<i>Fold 4</i>	0,0656	27,3135
<i>Fold 5</i>	0,0782	33,8063
<i>Fold 6</i>	0,0662	28,1372
<i>Fold 7</i>	0,0716	31,0538
<i>Fold 8</i>	0,0672	28,4759
<i>Fold 9</i>	0,0938	44,4805
<i>Fold 10</i>	0,0750	33,4965
<b>Erro médio</b>	<b>0,0800</b>	<b>34,6577</b>

Fonte: Elaborada pelo autor.

No presente experimento pode-se notar no decorrer dos testes que o *Dataset B2* apresenta um desempenho bastante similar em ambos os experimentos e em ambas as posições, alcançando um erro MAE normalizado em torno de 0,075 e em quilogramas em torno de 34 kg.

Utilizando os mesmos procedimentos foi realizado um experimento no *Dataset B3*, utilizando as imagens laterais entre o *Dataset annotation B3*, de silhueta R (somente o filtro na cor vermelha), apresentados na tabela 7, e o *Dataset images B3* em GS, apresentado na tabela 8.

**Tabela 7 - 10-Fold-Validation do *Dataset annotation B3* utilizando nas imagens de silhueta o tratamento de silhueta R com o animal na posição lateral.**

<i>Fold</i>	MAE (Normalizado [0,1])	MAE (Quilogramas)
<i>Fold 1</i>	0,0382	28,2243
<i>Fold 2</i>	0,0425	30,7200
<i>Fold 3</i>	0,0493	36,0463
<i>Fold 4</i>	0,0427	32,6381
<i>Fold 5</i>	0,0501	37,2450
<i>Fold 6</i>	0,0660	47,5709
<i>Fold 7</i>	0,0592	41,6693
<i>Fold 8</i>	0,0532	37,8815
<i>Fold 9</i>	0,0660	47,5599
<i>Fold 10</i>	0,0524	37,2322
<b>Erro médio</b>	<b>0,0519</b>	<b>37,6787</b>

Fonte: Elaborada pelo autor.

**Tabela 8 - 10-Fold-Validation do *Dataset images B3* utilizando nas imagens do animal o tratamento Tons de Cinza com o animal na posição lateral.**

<i>Fold</i>	MAE (Normalizado [0,1])	MAE (Quilogramas)
<i>Fold 1</i>	0,0510	29,2259
<i>Fold 2</i>	0,0476	29,5615
<i>Fold 3</i>	0,0530	33,6127
<i>Fold 4</i>	0,0524	32,7865
<i>Fold 5</i>	0,0602	37,1918
<i>Fold 6</i>	0,0738	47,7659
<i>Fold 7</i>	0,0656	41,5000
<i>Fold 8</i>	0,0595	37,6702
<i>Fold 9</i>	0,0757	46,3744
<i>Fold 10</i>	0,0634	38,5175
<b>Erro médio</b>	<b>0,0602</b>	<b>37,4206</b>

Fonte: Elaborada pelo autor.

Para o *Dataset B3*, foi realizado somente um experimento pois esse *Dataset* possui apenas imagens dos animais na posição lateral. O experimento apresentado obteve um

desempenho similar em ambos os tratamentos. Outra alteração que foi necessária foi a troca do filtro de cor pois as imagens que compunham os *Datasets* de *annotation* B3 e B4 as silhuetas eram em um tom rosa diferente do *Dataset annotation* B2 em que a silhueta era disposta na cor verde. Entre os três *Datasets* o B3 foi o que teve os melhores resultados.

Para o último dataset testado, o *Dataset* B4 dois experimentos foram realizados. O primeiro utilizando as figuras frontais entre os *Datasets images* B4 aplicando o filtro GS, apresentado na tabela 10, e *Datasets annotation* B4 aplicando o filtro R (somente vermelho), apresentado na tabela 9. O segundo experimento no *Dataset* B4 foi sobre as figuras laterais entre entre os *Datasets images* B4 aplicando o filtro GS, apresentado na tabela 12, e *Datasets annotation* B4 aplicando o filtro R (somente vermelho), apresentado na tabela 11.

**Tabela 9 - 10-Fold-Validation do Dataset annotation B4 utilizando nas imagens de silhueta o tratamento R com o animal na posição frontal.**

<i>Fold</i>	MAE (Normalizado [0,1])	MAE (Quilogramas)
<i>Fold 1</i>	0,1371	34,6611
<i>Fold 2</i>	0,1030	25,8208
<i>Fold 3</i>	0,0928	23,8193
<i>Fold 4</i>	0,0735	18,9411
<i>Fold 5</i>	0,0655	17,7564
<i>Fold 6</i>	0,0776	21,9351
<i>Fold 7</i>	0,1072	29,5714
<i>Fold 8</i>	0,1324	34,8442
<i>Fold 9</i>	0,2069	52,9974
<i>Fold 10</i>	0,1738	43,7622
<b>Erro médio</b>	<b>0,1169</b>	<b>30,4109</b>

Fonte: Elaborada pelo autor.

**Tabela 10 - 10-Fold-Validation do Dataset images B4 utilizando nas imagens o tratamento Tons de Cinza com o animal na posição frontal.**

<i>Fold</i>	MAE (Normalizado [0,1])	MAE (Quilogramas)
<i>Fold 1</i>	0,1368	33,1038
<i>Fold 2</i>	0,1232	29,3275
<i>Fold 3</i>	0,0883	21,3031
<i>Fold 4</i>	0,0759	18,0375
<i>Fold 5</i>	0,0602	37,1918
<i>Fold 6</i>	0,0738	47,7659
<i>Fold 7</i>	0,1128	32,0455
<i>Fold 8</i>	0,1469	39,3842
<i>Fold 9</i>	0,1869	52,3680
<i>Fold 10</i>	0,1580	41,0751
<b>Erro médio</b>	<b>0,1162</b>	<b>35,1602</b>

Fonte: Elaborada pelo autor.

**Tabela 11 - 10-Fold-Validation do Dataset annotation B4 utilizando nas imagens de silhueta, o tratamento R com o animal na posição lateral.**

<i>Fold</i>	MAE (Normalizado [0,1])	MAE (Quilogramas)
<i>Fold 1</i>	0,0988	27,5097
<i>Fold 2</i>	0,0843	22,2089
<i>Fold 3</i>	0,0756	20,5979
<i>Fold 4</i>	0,0716	20,6590
<i>Fold 5</i>	0,0666	18,9368
<i>Fold 6</i>	0,0754	22,1393
<i>Fold 7</i>	0,1128	32,0455
<i>Fold 8</i>	0,1469	39,3842
<i>Fold 9</i>	0,1869	52,3680
<i>Fold 10</i>	0,1580	41,0751
<b>Erro médio</b>	<b>0,1076</b>	<b>29,6924</b>

Fonte: Elaborada pelo autor.

**Tabela 12 - 10-Fold-Validation do Dataset images B4 utilizando o tratamento Tons de Cinza com o animal na posição lateral.**

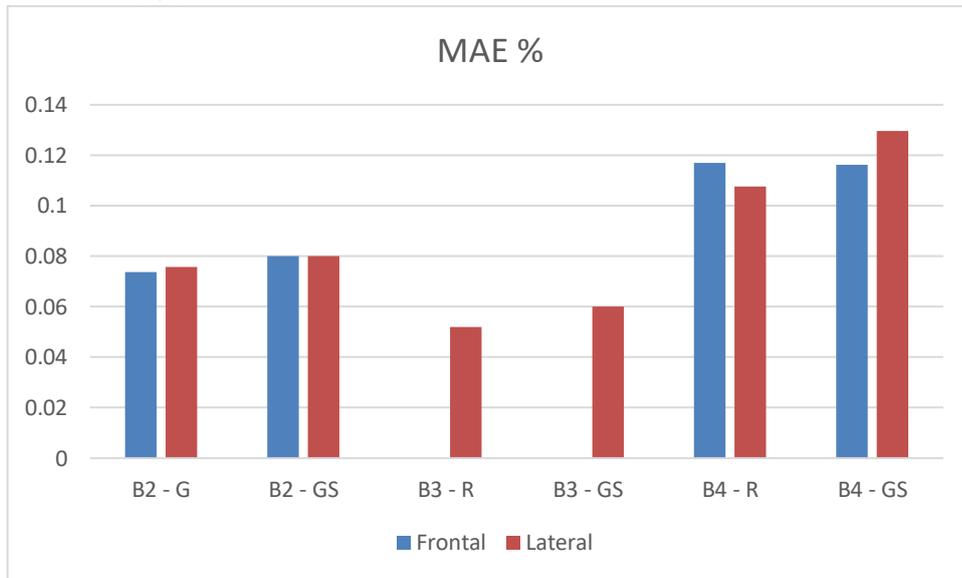
<i>Fold</i>	MAE (Normalizado [0,1])	MAE (Quilogramas)
<i>Fold 1</i>	0,1437	34,9004
<i>Fold 2</i>	0,1326	31,8198
<i>Fold 3</i>	0,1110	26,3776
<i>Fold 4</i>	0,0837	19,6691
<i>Fold 5</i>	0,0677	17,1399
<i>Fold 6</i>	0,0914	23,2895
<i>Fold 7</i>	0,1140	28,6604
<i>Fold 8</i>	0,1347	34,3975
<i>Fold 9</i>	0,2274	55,1928
<i>Fold 10</i>	0,1908	46,2134
<b>Erro médio</b>	<b>0,1297</b>	<b>31,7660</b>

Fonte: Elaborada pelo autor.

Os experimentos referentes ao *Dataset* B4 se mantiveram bastante estáveis, em ambos as posições o tratamento R se manteve consideravelmente superior em relação as imagens em Tons de Cinza, com as imagens nas posições laterais e frontais. Porém foram os experimentos com a pior performance entre os três *Datasets* (B2, B3 e B4).

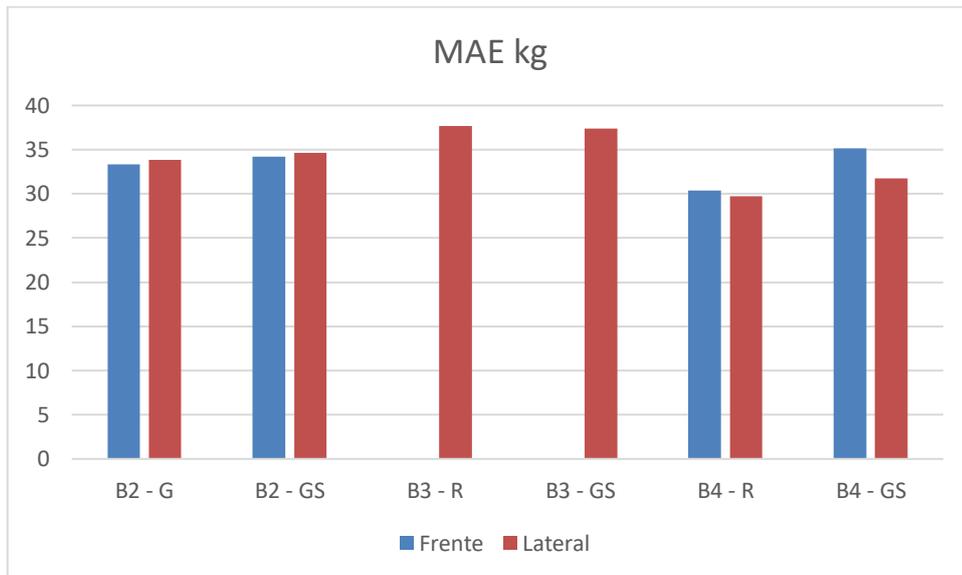
Abaixo são apresentados os erros percentuais desses três *Datasets* divididos entre o *Dataset* e o filtro aplicado (R G ou GS) pela posição da imagem (Frente, Lateral), apresentado no Gráfico 1. No Gráfico 2 está discriminado os valores absolutos dos erros médios apresentados em todos os experimentos segmentados também por *Dataset* e o filtro aplicado (R G ou GS) pela posição da imagem (Frente, Lateral).

**Gráfico 1 - Média dos resultados obtidos por meio da técnica 10-Fold-Validation utilizando a métrica MAE normalizada de [0,1].**



Fonte: Elaborado pelo autor.

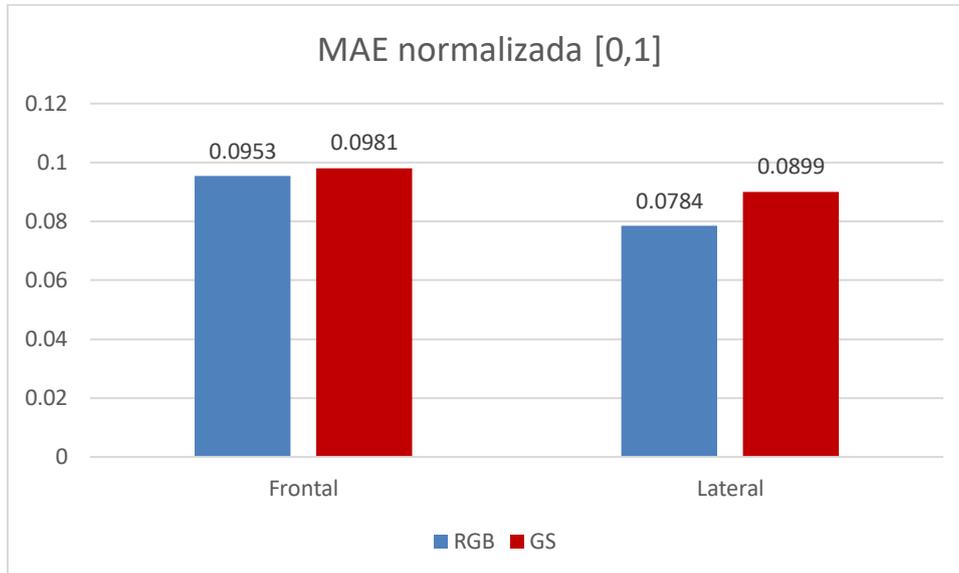
**Gráfico 2 - Resultados obtidos por meio da técnica 10-Fold-Validation utilizando a métrica MAE em quilogramas.**



Fonte: Elaborado pelo autor.

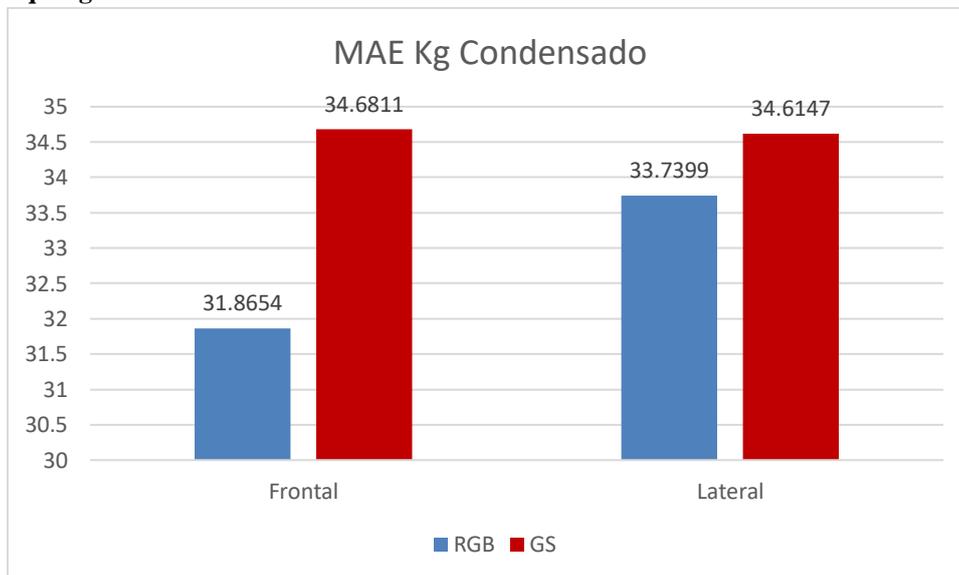
Por último A média entre os erros dos três Datasets são apresentadas nos gráficos 3 e 4. No gráfico 3, pode-se constatar que as imagens laterais têm um erro inferior as imagens frontais. No gráfico 4 também denota que em média as imagens de silhueta obtiveram um erro inferior as apresentadas em escala de cinza. Porém essa técnica necessita de um pré-processamento da imagem que não foi tratado no presente estudo.

**Gráfico 3 - Média dos resultados obtidos por meio da técnica 10-Fold-Validation utilizando a métrica MAE normalizada de [0,1].**



Fonte: Elaborada pelo autor.

**Gráfico 4 - Erros em quilogramas obtidos por meio da técnica 10-Fold-Validation utilizando a métrica MAE em quilogramas.**



Fonte: Elaborada pelo autor.

## 5 CONCLUSÃO

A pesagem de bovinos é de suma importância para conseguir atingir resultados consideráveis em produções agropecuárias (SANTOS, 2005), o *stress* animal por sua vez é um fator que atrapalha muito o desenvolvimento dos animais (SANTOS, 2005; ROSA, 2003). Com base nos testes e estudos do algoritmo apresentado neste estudo foi possível constatar que a pesagem dos animais pode ser viável por meio de Redes Neurais Convolucionais. Atingindo uma taxa de erro mínima de 31,86 quilogramas utilizando a técnica *k-Fold validation* juntamente com a métrica MAE para aferir sua eficácia. Por sua vez foi constatado que o algoritmo se saiu mais assertivo quando foi analisado as imagens dos animais na posição lateral utilizando o tratamento RGB apresentado nos *Datasets* (Acme AI Ltd. et al., 2023).

Sendo assim é indicada essa configuração para alcançar os melhores resultados de pesagem de bovinos por meio de Redes Neurais Convolucionais usando os *Datasets* adquiridos para o treinamento.

## REFERÊNCIAS

ANDREW, W. et al. **Visual identification of individual Holstein-Friesian cattle via deep metric learning**. Computers and Electronics in Agriculture, v. 185, p. 106133, 2021.

MOREIRA, G. M. de O. **Bovinocultura de corte no Brasil: sistema de criação**. 2016. Trabalho de Conclusão de Curso – Instituto Federal de São Paulo – Campus Barretos, 2016.

ALVARENGA, S. R. de. **Bem-estar animal e sua influência na bovinocultura de corte**. 2022. Trabalho de Conclusão de Curso (Graduação em Zootecnia) – Pontifícia Universidade Católica de Goiás, Escola de Ciências Médicas e da Vida, Goiânia, 2022. Disponível em: <<https://repositorio.pucgoias.edu.br/jspui/handle/123456789/4417>>. Acesso em: 28 maio. 2024.

ACCO, A. et al. **Síndrome do Estresse em Animais - Revisão**. Arquivos de Ciências Veterinárias e Zoologia da UNIPAR, p. 71-76, v. 2, n. 1, 2008.

ALVES, L. G. et al. **Bem-estar e manejo pré-abate e suas influências sobre a qualidade de carne e carcaça de bovinos de corte**. ENCICLOPÉDIA BIOSFERA, v. 16, n. 29, 2019.

BERNARDO, S.; FONTES B., L.; THOMAZ, C. **Reconhecimento de Faces por Aprendizado Profundo: Dropout em Autoencoders**. 2018. Disponível em: <[https://fei.edu.br/sites/sicfei/2018/eletrica/SICFEI\\_2018\\_paper\\_68.pdf](https://fei.edu.br/sites/sicfei/2018/eletrica/SICFEI_2018_paper_68.pdf)>. Acesso em: 22 maio. 2024.

CHARNIAK, E. **Introduction to Deep Learning**. 1. ed. [S.l.: s.n.]: The MIT Press, 2019. ISBN 0262039516; 9780262039512.

DSA, E. **Camadas de Pooling em Redes Neurais Convolucionais**. Disponível em: <<https://www.deeplearningbook.com.br/camadas-de-pooling-em-redes-neurais-convolucionais/>>. Acesso em: 22 maio. 2024.

ESTEVEVES, T. **A desvantagem da função ReLU**. 2022. Disponível em: <[https://estevestoni.medium.com/a-desvantagem-de-utilizar-relu-4478589ef834#:~:text=Rectified%20Linear%20Unit%20\(ReLU\)](https://estevestoni.medium.com/a-desvantagem-de-utilizar-relu-4478589ef834#:~:text=Rectified%20Linear%20Unit%20(ReLU))>. Acesso em: 22 maio. 2024.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S.l.: s.n.]: MIT, 2017.

MELO, A. F. et al. **Fatores que influenciam na qualidade da carne bovina: Revisão**. Publicações em Medicina Veterinária e Zootecnia, v. 10, n. 10, p. 785- 794, 2016.

LIU, M.; YAO, D.; LIU, Z.; GUO, J.; CHEN, J. An improved Adam optimization algorithm combining adaptive coefficients and composite gradients based on randomized block coordinate descent. *Computational Intelligence and Neuroscience*, v. 2023, p. 1-14, 2023. DOI: 10.1155/2023/4765891.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Bookman Editora, 2001.

MENDONÇA, F. S. et al. **Fatores que afetam o bem-estar de bovinos durante o período pré-abate**. *Archivos de zootecnia*, v. 65, n. 250, p. 279-287, 2016.

MURPHY, K. P. **Machine Learning: A Probabilistic Perspective**. 1. ed. [S.l.: s.n.]: The MIT Press, 2012. (Adaptive Computation and Machine Learning). ISBN 9780262018029.

ORSINI, H. B; FERNANDES, E. **Fisiopatologia do Estresse em Animais Selvagens em Cativo e suas Implicações no Comportamento e Bem-estar - revisão de literatura**. *Revista do Instituto Ciência Saúde*, v. 24, n. 1, p. 7-13, 2006.

MEDEIROS, S. R. de; GOMES, R. da C.; BUNGENSTAB, D. J. 1. ed. **Nutrição de bovinos de corte: fundamentos e aplicações**. Brasília, DF: Embrapa, 2015. 176 p. ISBN 978-85-7035-419-8.

ROSA, J. P; **Endocrinologia do estresse e Importância no Bem-estar Animal**. Universidade Federal do Rio Grande do Sul, 2003.

SANTOS, E. O. **Metabolismo do Estresse: impactos na saúde e na produção animal**. Universidade Federal do Rio Grande do Sul, 2005.

SENAR, C. **Bovinocultura: manejo e alimentação de bovinos de corte em confinamento**. 2018. Disponível em: <<https://www.cnabrazil.org.br/assets/arquivos/232-BOVINOCULTURA.pdf>>.

ZUARDI, A.W. **Fisiologia do estresse e sua influência na saúde**. Programa de pós-graduação em Ciências da Saúde na UFU. Uberlândia, 2015.

FERREIRA, N. **Transição de dietas: o que fazer para minimizar os prejuízos ruminais**. Disponível em: <<https://opresenterural.com.br/transicao-de-dietas-o-que-fazer-para-minimizar-os-prejuizos-ruminais/>>. Acesso em: 22 maio. 2024.

BARTH, N. L.; SAMARTINI, A.; SICSÚ, A. L. **Técnicas de machine learning**. 1. ed. São Paulo. Blücher, 2023.