

Universidade Federal do Piauí
Centro de Ciências da Natureza
Programa de Pós-Graduação em Ciência da Computação

Desenvolvimento e Avaliação de um Sistema para Estimativa Automatizada de Peso de Pequenos Ruminantes Integrando Visão Computacional e Arquitetura Local-First

Anthony Irlan Marques Luz

Teresina-PI, Fevereiro de 2026

Anthony Irlan Marques Luz

Desenvolvimento e Avaliação de um Sistema para Estimativa Automatizada de Peso de Pequenos Ruminantes Integrando Visão Computacional e Arquitetura Local-First

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da UFPI (área de concentração: Sistemas de Computação), como parte dos requisitos necessários para a obtenção do Título de Mestre em Ciência da Computação.

Universidade Federal do Piauí – UFPI

Centro de Ciências da Natureza

Programa de Pós-Graduação em Ciência da Computação

Orientador: Romuere Rodrigues Veloso e Silva

Teresina-PI

Fevereiro de 2026

FICHA CATALOGRÁFICA
Universidade Federal do Piauí
Sistema de Bibliotecas UFPI - SIBI/UFPI
Biblioteca Setorial do CCN

L979d Luz, Anthony Irlan Marques.
Desenvolvimento e avaliação de um sistema para estimativa automatizada de peso de pequenos ruminantes integrando visão computacional e arquitetura local-first / Anthony Irlan Marques Luz. -- 2026.
100 f. : il.

Dissertação (Mestrado) - Universidade Federal do Piauí. Centro de Ciências da Natureza. Programa de Pós-Graduação Ciência da Computação. Teresina, 2026.
"Orientador: Prof. Dr. Romuere Rodrigues Veloso e Silva. "

1. Visão Computacional. 2. Pequenos Ruminantes. 3. Aprendizado Profundo. 4. Computação de Borda. I. Silva, Romuere Rodrigues Veloso e. II. Titulo.

CDD 004.77

Bibliotecária: Caryne Maria da Silva Gomes - CRB3/1461

Anthony Irlan Marques Luz

Desenvolvimento e Avaliação de um Sistema para Estimativa Automatizada de Peso de Pequenos Ruminantes Integrando Visão Computacional e Arquitetura Local-First

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da UFPI (área de concentração: Sistemas de Computação), como parte dos requisitos necessários para a obtenção do Título de Mestre em Ciência da Computação.

Trabalho aprovado. Teresina-PI, 27 de fevereiro de 2026:

Documento assinado digitalmente
gov.br
ROMUERE RODRIGUES VELOSO E SILVA
Data: 14/05/2026 08:50:55-0300
Verifique em https://validar.iti.gov.br

Romuere Rodrigues Veloso e Silva
Orientador

Documento assinado digitalmente
gov.br
ANTONIO OSEAS DE CARVALHO FILHO
Data: 08/05/2026 10:34:59-0300
Verifique em https://validar.iti.gov.br

Antonio Oseas de Carvalho Filho
Membro interno

Documento assinado digitalmente
gov.br
NATANAEL PEREIRA DA SILVA SANTOS
Data: 08/05/2026 10:00:48-0300
Verifique em https://validar.iti.gov.br

Natanael Pereira da Silva Santos
Membro externo

Documento assinado digitalmente
gov.br
IALIS CAVALCANTE DE PAULA JUNIOR
Data: 08/05/2026 10:08:05-0300
Verifique em https://validar.iti.gov.br

Iális Cavalcante de Paula Júnior
Membro externo

Teresina-PI
Fevereiro de 2026

Resumo

A ovinocaprinocultura desempenha um papel fundamental na economia do Nordeste brasileiro e na agricultura familiar, contudo, o monitoramento zootécnico — essencial para a eficiência produtiva — é frequentemente negligenciado devido às dificuldades operacionais e ao estresse animal associados à pesagem tradicional. Embora a literatura apresente avanços no uso de visão computacional para biometria animal, a maioria das soluções permanece restrita a ambientes controlados ou depende de infraestrutura de conectividade incompatível com a realidade rural. Esta dissertação propõe, implementa e avalia um sistema ponta a ponta para estimativa automatizada de peso de pequenos ruminantes em condições de campo, integrando um dispositivo de captura embarcado e um aplicativo móvel baseado na arquitetura Local-First. O pipeline de processamento combina detecção de objetos, segmentação semântica e redes neurais convolucionais (CNNs) para regressão a partir de imagens laterais. Os resultados experimentais demonstraram que a resolução de entrada de 1024×1024 píxeis foi determinante para a estabilidade das estimativas e que a segmentação automática apresentou desempenho preditivo estatisticamente próximo à segmentação manual, com RMSE de 3,43 kg no melhor cenário automatizado. Adicionalmente, a aplicação da técnica de otimização Low-Rank Adaptation (LoRA) no modelo de segmentação permitiu reduzir o tamanho do checkpoint de centenas de megabytes para aproximadamente 15 MB, preservando métricas de Dice e IoU superiores a 0,95, o que viabiliza a atualização remota do sistema em áreas com conectividade limitada. Por fim, a avaliação de usabilidade (SUS) indicou uma pontuação média global de 75,7, considerada boa, embora tenha evidenciado a necessidade de interfaces adaptadas para usuários com menor letramento digital. O trabalho conclui que a solução proposta é tecnicamente viável e operacionalmente robusta para o suporte à decisão na pecuária de precisão

Palavras-chave: Visão Computacional. Estimativa de Peso. Pequenos Ruminantes. Aprendizado Profundo. Computação de Borda.

Abstract

Small ruminant farming plays a fundamental role in the economy of Northeastern Brazil and family farming; however, zootechnical monitoring—essential for productive efficiency—is often neglected due to operational difficulties and animal stress associated with traditional weighing. Although the literature presents advances in using computer vision for animal biometrics, most solutions remain restricted to controlled environments or rely on connectivity infrastructure incompatible with rural reality. This dissertation proposes, implements, and evaluates an end-to-end system for automated weight estimation of small ruminants under field conditions, integrating an embedded capture device and a mobile application based on a Local-First architecture. The processing pipeline combines object detection, semantic segmentation, and Convolutional Neural Networks (CNNs) for regression from lateral images. Experimental results showed that an input resolution of 1024×1024 pixels was decisive for estimation stability and that automated segmentation presented predictive performance statistically close to manual segmentation , with an RMSE of 3.43 kg in the best automated scenario. Additionally, applying the Low-Rank Adaptation (LoRA) optimization technique to the segmentation model allowed reducing the checkpoint size from hundreds of megabytes to approximately 15 MB while preserving Dice and IoU metrics above 0.95, enabling remote system updates in areas with limited connectivity. Finally, the usability evaluation (SUS) indicated an overall average score of 75.7, considered good, although it highlighted the need for interfaces adapted for users with lower digital literacy. The work concludes that the proposed solution is technically viable and operationally robust for decision support in precision livestock farming.

Keywords: Computer Vision. Weight Estimation. Small Ruminants. Deep Learning. Edge Computing.

Lista de ilustrações

Figura 1 – Representação esquemática do fluxo de processamento em uma CNN típica, desde a imagem de entrada, passando pelas camadas de convolução e redução espacial, até a geração da saída do modelo. 6

Figura 2 – Representação esquemática da arquitetura U-Net, destacando o caminho de contração (*encoder*), o caminho de expansão (*decoder*) e as conexões de atalho que combinam contexto semântico e detalhes espaciais para a geração da máscara de segmentação. 8

Figura 3 – Exemplo de pesagem convencional em estrutura física dedicada, evidenciando a necessidade de condução do animal, contenção e uso de equipamento específico para obtenção do peso. 11

Figura 4 – Representação conceitual da tarefa de regressão supervisionada: associação entre a imagem de entrada e o rótulo de peso corporal. 12

Figura 5 – Exemplos de cenários reais e não padronizados de coleta em ambiente rural: (a) curral externo com alta densidade de animais; (b) curral externo com configuração espacial distinta; (c) instalação coberta com cochos e pilares centrais; (d) instalação coberta alongada com organização diferente do manejo. 14

Figura 6 – Arquitetura conceitual *Local-First* aplicada. 15

Figura 7 – Fluxograma da metodologia proposta. 21

Figura 8 – Esquema do posicionamento da câmera em relação ao animal. 22

Figura 9 – Procedimento de aferição manual do peso utilizando balança suspensa. 23

Figura 10 – Exemplo de máscara binária. 23

Figura 11 – Exemplos de ativações espúrias na etapa de detecção por subtração de fundo: (a) solo; (b) vegetação/base da estrutura; (c) ruído periférico; (d) sombra e elementos estruturais. 25

Figura 12 – Pipeline proposto para estimativa de peso. Os frames são segmentados individualmente, processados pela CNN e agregados via média antes da regressão. 27

Figura 13 – Arquitetura do sistema proposto. 29

Figura 14 – Diagrama de Casos de Uso do Sistema Proposto. 32

Figura 15 – Pontuação SUS por usuário, (FT marcados em azul e NFT marcados em vermelho). 44

Figura 16 – Distribuição da pontuação SUS por perfil de participante. 45

Figura 17 – Relação exploratória entre idade e pontuação SUS. 46

Figura 18 – Tela inicial do aplicativo móvel (Menu Principal), destacando as opções de gestão e os métodos de coleta de dados de peso, com ênfase na coleta automática. 58
Figura 19 – Tela de listagem do rebanho, apresentando cartões individuais com resumo de identificação, raça e a última medição de peso registrada para o animal. 59
Figura 20 – Modal de seleção de propriedades rurais, permitindo ao produtor filtrar a listagem de animais de acordo com a fazenda de origem. 60
Figura 21 – Modal de seleção de lotes, refletindo a organização prática do manejo zootécnico e facilitando a busca em grandes rebanhos. 61
Figura 22 – Perfil individual do animal apresentando dados cadastrais e o histórico de pesagens. Destaca-se a diferenciação visual e textual entre coletas de dados automáticas (via visão computacional) e manuais. 62
Figura 23 – Menu do módulo de Coleta Manual, com opções para iniciar um novo manejo ou acessar o histórico local. 64
Figura 24 – Tela de configuração da sessão de coleta, registrando metadados de manejo como data, período, responsável, propriedade e lote. 65
Figura 25 – Interface de seleção de animais dentro do lote configurado para a sessão de coleta. 66
Figura 26 – Detalhe do *feedback* visual indicando a seleção bem-sucedida de um animal para o registro de dados. 67
Figura 27 – Aba principal de registro zootécnico, contendo campos para inserção manual do peso (kg) e do Escore de Condição Corporal (ECC). 68
Figura 28 – Aba de avaliação CPM, permitindo o registro de escores de Conformação, Precocidade e Musculatura. 69
Figura 29 – Formulário de coleta de medidas verticais, incluindo altura da garupa, cernelha e perna. 70
Figura 30 – Aba dedicada às medidas horizontais e longitudinais do animal. 71
Figura 31 – Interface para inserção de perímetros e circunferências corporais, com destaque para a circunferência torácica, frequentemente correlacionada com o peso vivo. 72
Figura 32 – Formulário para registro de larguras entre pontos anatômicos específicos (ísquios e ílios). 73
Figura 33 – Interface de histórico de coletas manuais, evidenciando o status de sincronização dos pacotes de dados (*Local* vs. *Enviado*), característica fundamental da arquitetura *Local-First*. 74
Figura 34 – Interface principal do sistema, evidenciando o acesso ao módulo de Coleta Automática, elemento central para a operação do sistema de pesagem por visão computacional. 76

Figura 35 – Menu do módulo de Coleta Automática, destacando a rotina de sincronização entre o dispositivo móvel do usuário e o hardware de borda posicionado no campo. 77
Figura 36 – Tela de configuração da sessão de coleta automática, garantindo a indexação correta dos dados inferidos pelo algoritmo no banco de dados local. 78

Lista de tabelas

Tabela 1 – Resumo dos principais estudos sobre predição de peso em pequenos ruminantes. 19
Tabela 2 – Requisitos funcionais. 30
Tabela 3 – Requisitos não funcionais. 30
Tabela 4 – Configurações e hiperparâmetros de treinamento para segmentação. . . 33
Tabela 5 – Comparação de desempenho entre diferentes extratores de características (CNN) usando Regressão Linear. Resultados obtidos com a base segmentada manualmente. 35
Tabela 6 – Resultados do método de *ensemble* para estimativa de peso. 36
Tabela 7 – Resultados comparativos de desempenho das variantes de segmentação baseadas em U-Net. 36
Tabela 8 – Comparação de complexidade e custo computacional das variantes de segmentação. 37
Tabela 9 – Comparação descritiva entre trabalhos relacionados e o pipeline proposto. 38
Tabela 10 – Critérios de referência para interpretação. 40
Tabela 11 – Linhas de código (LOC) por componente (excluindo testes). 40
Tabela 12 – Resumo de complexidade ciclomática (CC) por componente. 40
Tabela 13 – Menores índices de manutenibilidade encontrados no BFF. 41
Tabela 14 – Perguntas utilizadas no questionário. 43
Tabela 15 – Estatísticas descritivas da pontuação SUS por perfil. 43

Lista de abreviaturas e siglas

Adam	*Adaptive Moment Estimation*
API	*Application Programming Interface*
BFF	*Backend for Frontend*
CC	Complexidade Ciclomática (*Cyclomatic Complexity*)
CKPT	*Checkpoint* (Arquivo de modelo salvo)
CNN	Rede Neural Convolucional (*Convolutional Neural Network*)
CSA	*Cuckoo Search Algorithm*
CV	Visão Computacional (*Computer Vision*)
DP	Desvio Padrão
FPN	*Feature Pyramid Network*
FIT	*Fine-Tuning* (Ajuste fino)
FT	Familiarizados com Tecnologia (Perfil de usuário)
GA	Algoritmo Genético (*Genetic Algorithm*)
IoU	Interseção sobre União (*Intersection over Union*)
ISO	*International Organization for Standardization*
LOC	Linhas de Código (*Lines of Code*)
LoRA	*Low-Rank Adaptation*
MAE	Erro Absoluto Médio (*Mean Absolute Error*)
MAPE	Erro Percentual Absoluto Médio (*Mean Absolute Percentage Error*)
MI	Índice de Manutenibilidade (*Maintainability Index*)
MVP	Produto Mínimo Viável (*Minimum Viable Product*)
NFT	Não Familiarizados com Tecnologia (Perfil de usuário)
RF	*Random Forest*

RGB	*Red, Green, Blue* (Modelo de cor)
RGB-D	*Red, Green, Blue - Depth* (Cor e Profundidade)
RMSE	Raiz do Erro Quadrático Médio (*Root Mean Square Error*)
ROI	Região de Interesse (*Region of Interest*)
SUS	Escala de Usabilidade de Sistemas (*System Usability Scale*)
SVM	Máquina de Vetores de Suporte (*Support Vector Machine*)
SVR	Regressão de Vetores de Suporte (*Support Vector Regression*)
TL	*Transfer Learning*
UML	Linguagem de Modelagem Unificada (*Unified Modeling Language*)

Lista de símbolos

A_t	Variável de ativação do evento de captura no instante t
b_t	Caixa delimitadora (*bounding box*) detectada no instante t
E	Número de arestas no grafo de fluxo de controle
i	Índice da amostra ou iteração ($1 \leq i \leq n$)
N	Número de nós no grafo de fluxo de controle
n	Número total de *frames* ou amostras
P	Número de componentes conectados no grafo de fluxo
R^2	Coeficiente de determinação
r	Região de interesse (ROI) ou Coeficiente de correlação
$v(G)$	Complexidade Ciclomática
$\mathbf{v}_i$	Vetor de características extraído do i-ésimo *frame*
$\bar{\mathbf{v}}$	Vetor médio de características da amostra
y_i	Valor real (peso observado) da i-ésima amostra
$\hat{y}_i$	Valor predito (peso estimado) da i-ésima amostra
$\bar{y}$	Média dos valores reais da variável dependente
θ_{IoU}	Limiar (*threshold*) de Interseção sobre União para ativação

Sumário

1 INTRODUÇÃO 1
1.1 Problema 1
1.2 Objetivos 2
1.2.1 Objetivo geral 2
1.2.2 Objetivos específicos 2
1.3 Contribuições 3
1.4 Publicações 3
1.5 Organização 4

2 REFERENCIAL TEÓRICO 5
2.1 Visão computacional e aprendizado profundo 5
2.1.1 Região de interesse (ROI) e controle da entrada visual 6
2.1.2 Avaliando a qualidade da segmentação 8
2.1.3 Estratégias de adaptação, regularização e validação 9
2.2 Predição de peso animal 10
2.2.1 Métricas de avaliação de desempenho 12
2.3 Sistemas computacionais aplicados ao ambiente rural 13
2.4 Avaliação da qualidade de software e usabilidade 16
2.4.1 Usabilidade e a escala SUS 16
2.4.2 Métricas estáticas de manutenibilidade 16

3 ESTADO DA ARTE 19

4 MODELO DE VISÃO COMPUTACIONAL PARA ESTIMATIVA DE PESO 21
4.1 Aquisição de dados 21
4.2 Detecção 24
4.3 Segmentação e estimativa 26

5 SISTEMA PROPOSTO 29
5.0.1 Elicitação de requisitos 30
5.0.2 Modelagem 30

6 RESULTADOS 33
6.1 Métricas de Predição de Peso 33
6.1.1 Configurações de treinamento para segmentação 33
6.1.2 Protocolo experimental para regressão do peso 34

6.1.3 Resultados com diferentes extratores de características e resoluções 34
6.1.4 Estratégias de melhora 35
6.1.5 Otimização do modelo de segmentação para uso em campo 36
6.2 Comparação com trabalhos relacionados 38
6.3 Métricas de Qualidade de Código 39
6.3.1 Critérios de Avaliação 39
6.3.2 Tamanho do Sistema 40
6.3.3 Complexidade Ciclomática 40
6.3.4 Índice de Manutenibilidade 41
6.3.5 Síntese dos Resultados 41
6.4 Avaliação de Usabilidade 42

7 CONCLUSÃO 47

REFERÊNCIAS 49

APÊNDICES 55

APÊNDICE A – INTERFACES DO APLICATIVO MÓVEL 57
A.1 Módulo de Gestão 57
A.2 Módulo de Coleta Manual e Fenotipagem 57
A.3 Módulo de Coleta Automática e Integração na Borda 74

1 Introdução

Segundo IBGE (2025), o Brasil ocupa atualmente posições de destaque no ranking mundial de criação de pequenos ruminantes, sendo o 18º em ovinos e o 21º em caprinos. Esses rebanhos encontram-se fortemente concentrados na região Nordeste, responsável por aproximadamente 90% da caprinocultura nacional e cerca de 64% da ovinocultura (EMBRAPA, 2023). Estimativas da Empresa Brasileira de Pesquisa Agropecuária indicam que cerca de 73% da atividade nacional está inserida no contexto da agricultura familiar (EMBRAPA, 2025), caracterizada por pequenas propriedades, escassez de recursos de investimento e infraestrutura tecnológica limitada.

O monitoramento zootécnico sistemático — com destaque para a mensuração do peso vivo — é um elemento estratégico para a eficiência produtiva, subsidiando decisões sobre nutrição, sanidade e comercialização (MORGAN-DAVIES et al., 2024; CARVALHO et al., 2017). Contudo, os métodos tradicionais (balanças e fitas métricas) são onerosos, estressantes para os animais e dependentes de contenção física e mão de obra especializada, o que torna a pesagem uma prática esporádica e dificulta a gestão baseada em dados (RABELLO; BRAGA; SCHULTZ, 2023).

A visão computacional surge como uma alternativa não invasiva promissora. Entretanto, a literatura concentra-se majoritariamente em experimentos controlados ou soluções que exigem conectividade constante e hardware robusto, ignorando as restrições reais do campo, como a intermitência de internet e a necessidade de dispositivos de baixo custo e manutenção simplificada (Walsh Medical Media, 2023; SILVA, 2024).

Diante desse quadro, esta dissertação propõe, implementa e avalia um sistema completo para estimativa automatizada de peso. A solução integra um dispositivo embarcado para captura e processamento na borda, algoritmos de aprendizagem profunda otimizados e um aplicativo móvel. O trabalho não se limita à modelagem algorítmica, mas avança sobre a engenharia de software necessária para tornar a inteligência artificial operável em propriedades rurais com conectividade restrita.

1.1 Problema

O problema central abordado nesta pesquisa é a lacuna entre os avanços obtidos por modelos acadêmicos de visão computacional para pesagem animal e sua aplicação efetiva na realidade operacional das propriedades rurais. Embora o estado da arte apresente resultados promissores em termos de desempenho preditivo em ambientes controlados, ainda são limitadas as soluções capazes de transformar esses modelos em ferramentas

viáveis para uso em campo.

Especificamente, os desafios técnicos envolvem: (i) o processamento de imagens capturadas em condições reais, com fundo variável e iluminação natural, sem dependência de servidores em nuvem em tempo real; (ii) a viabilidade de execução de modelos de segmentação e regressão em dispositivos com recursos computacionais limitados; e (iii) a oferta de interfaces de software utilizáveis por produtores com diferentes níveis de letramento digital. A ausência de sistemas que integrem o fluxo completo, desde a captura da imagem até a disponibilização da estimativa de peso ao produtor, com operação *offline*, limita a adoção em larga escala da pecuária de precisão em contextos de agricultura familiar.

Diante disso, estabelece-se a seguinte questão de pesquisa: é possível estimar automaticamente o peso corporal de pequenos ruminantes em condições reais de campo, a partir de imagens obtidas em ambiente não controlado, de forma operacionalmente viável em cenários com restrições de conectividade e infraestrutura

Como hipótese científica, assume-se que um pipeline baseado em segmentação automática e regressão profunda pode viabilizar a estimativa automática do peso corporal de pequenos ruminantes em condições reais de campo, com execução em dispositivos de recursos limitados e operação adequada a contextos rurais com conectividade restrita.

1.2 Objetivos

1.2.1 Objetivo geral

Desenvolver e avaliar uma abordagem para estimativa automática do peso de pequenos ruminantes que integre técnicas de visão computacional e uma arquitetura de software voltada à operação *offline* em ambientes rurais.

1.2.2 Objetivos específicos

Para alcançar o objetivo geral, foram definidos os seguintes objetivos específicos:

- Implementar um *pipeline* de visão computacional composto por detecção, segmentação semântica e regressão, capaz de isolar a silhueta do animal e inferir o peso a partir de imagens laterais;

- Avaliar o impacto de variáveis operacionais no desempenho preditivo, comparando a eficácia da segmentação automática versus manual e a influência da resolução da imagem na precisão da estimativa;

- Investigar estratégias de otimização de modelos para manutenção em campo, visando a redução de custo de armazenamento e atualização;

- Desenvolver uma arquitetura de software distribuída composta por dispositivo embarcado e aplicativo móvel, garantindo persistência local de dados e sincronização eventual;

- Avaliar a qualidade interna do software e a usabilidade do sistema, considerando perfis de usuários com diferentes níveis de familiaridade tecnológica.

1.3 Contribuições

As principais contribuições desta dissertação, consolidadas a partir dos experimentos e desenvolvimentos realizados, são:

- Validação da viabilidade da segmentação automática: Demonstração de que o uso de máscaras geradas automaticamente apresenta impacto marginal no erro de regressão quando comparado ao uso de máscaras manuais, validando a operação autônoma do sistema.

- Estratégia eficiente de atualização de modelos: A aplicação das técnicas permitiu reduzir drasticamente o tamanho dos arquivos de atualização sem perda estatística de desempenho, viabilizando ciclos de manutenção em locais com internet limitada.

- Arquitetura de sistema para o meio rural: A proposição e implementação de uma arquitetura que desacopla a operação de campo da disponibilidade de nuvem, garantindo autonomia ao produtor.

1.4 Publicações

Como resultado direto das pesquisas desenvolvidas nesta dissertação, foram produzidos os seguintes artigos científicos:

- **LUZ, ANTHONY I. M.**; SILVA, ROMUERE R. V. **Development and Evaluation of a System for Automated Weight Estimation of Small Ruminants Using Computer Vision**. Submetido para a revista *Smart Agricultural Technology*, 2026. (Em revisão).

- MARQUES, JÚLIO V. M.; SANTOS, WILLIANS S.; **LUZ, ANTHONY I. M.**; ARAÚJO, RAFAEL L.; DE SOUSA, ALCILENE D.; SARMENTO, JOSE L. R.;

SILVA, ROMUERE R. V. **U-Net + Transformer Encoder and Lora Adaptation for Rural Sheep Segmentation**. In: *2025 38th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*, Salvador, p. 1, 2025.

- ARAÚJO, RAFAEL L.; MARQUES, JÚLIO V. M.; **LUZ, ANTHONY I. M.**; SANTOS, MARINA C. M.; SANTOS NETO, JOÃO DOS; SOUSA, ALCILENE D. DE; VERAS, FRANK C. L.; CARVALHO FILHO, ANTÔNIO O. DE; V. E SILVA, ROMUERE R. **A Weight Monitoring Platform for Small Ruminants Using U-Net and EfficientNetB1**. In: *Anais do XXII Encontro Nacional de Inteligência Artificial e Computacional (ENIAC 2025)*, Brasil, p. 201, 2025.

1.5 Organização

Esta dissertação está organizada em sete capítulos. O Capítulo 2 fundamenta os conceitos de visão computacional, aprendizado profundo e métricas de avaliação, além de discutir os paradigmas da computação aplicada ao meio rural. O Capítulo 3 apresenta uma revisão comparativa das abordagens existentes para pesagem não invasiva. Os Capítulos 4 e 5 detalham a metodologia adotada, descrevendo desde o processo de coleta manual e treinamento dos modelos até a arquitetura do sistema proposto. O Capítulo 6 discute os experimentos realizados sob as perspectivas de desempenho preditivo, qualidade de código e usabilidade. Por fim, o Capítulo 7 sintetiza as descobertas, as limitações do estudo e propõe direções para trabalhos futuros.

2 Referencial Teórico

2.1 Visão computacional e aprendizado profundo

A visão computacional (do inglês *computer vision*, CV) é o campo da inteligência artificial dedicado à extração automática de significado de imagens e vídeos, replicando capacidades humanas como reconhecimento de objetos e cena (SZELISKI, 2022). Historicamente, métodos clássicos dependiam de *features hand-crafted* — descritores geométricos (LOWE, 2004), de textura ou gradientes (DALAL; TRIGGS, 2005) —, projetados manualmente por especialistas (SZELISKI, 2022). Eficazes em condições controladas, essas técnicas falham diante de variações em iluminação, escala, oclusões, fundos complexos e posturas, problemas agravados em cenários rurais com vegetação irregular e condições ambientais variáveis (WANG; VELDHUIS; STRISCIUGLIO, 2023).

O advento do aprendizado profundo representou uma mudança de paradigma nesse contexto, ao permitir que modelos aprendam automaticamente representações hierárquicas diretamente dos dados brutos (LECUN; BENGIO; HINTON, 2015). Nesse cenário, as redes neurais convolucionais (do inglês *Convolutional Neural Network*, CNN) consolidaram-se como o arcabouço dominante para tarefas de visão computacional, por explorarem a correlação espacial dos píxeis via operações de convolução e compartilhamento de pesos (SZELISKI, 2022). Em termos gerais, uma CNN transforma a imagem de entrada em uma sequência de representações internas progressivamente mais abstratas: nas camadas iniciais, a rede aprende padrões locais simples, como bordas, contrastes e texturas; em camadas mais profundas, essas respostas são combinadas para representar formas, partes do objeto e configurações visuais mais complexas (GOODFELLOW; BENGIO; COURVILLE, 2016).

A Figura 1 apresenta esse fluxo de processamento de maneira conceitual. À esquerda, a imagem de entrada é submetida a filtros convolucionais, que deslizam sobre a grade de píxeis e produzem mapas de características sensíveis a determinados padrões visuais. Em seguida, operações de redução espacial, como o *pooling*, condensam essas ativações, diminuindo a dimensionalidade da representação e tornando o modelo menos sensível a pequenas variações de posição. À medida que o sinal avança pelas camadas, os mapas de características deixam de representar diretamente os píxeis originais e passam a codificar atributos visuais de maior nível semântico. Na porção final da arquitetura, essas representações são agregadas e encaminhadas às camadas densas, responsáveis pela produção da saída da rede, como classificação ou regressão, a depender da tarefa considerada (GOODFELLOW; BENGIO; COURVILLE, 2016).

Embora a Figura 1 ilustre uma CNN em sua forma mais tradicional, com camadas

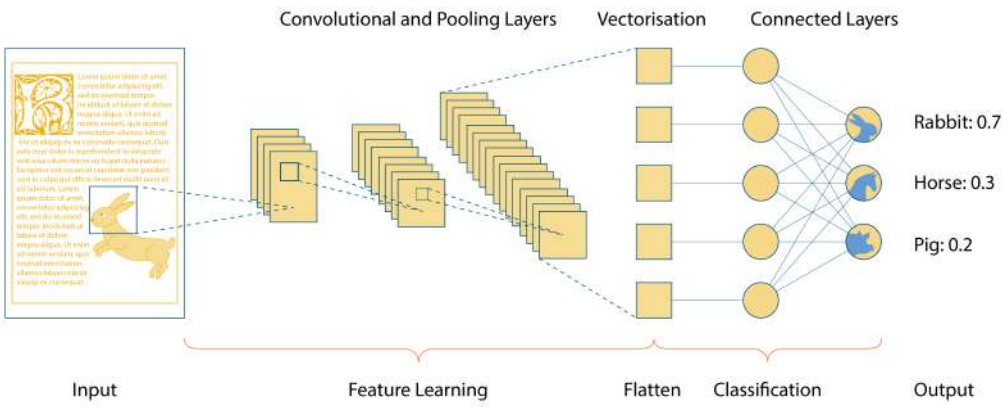


Figura 1 – Representação esquemática do fluxo de processamento em uma CNN típica, desde a imagem de entrada, passando pelas camadas de convolução e redução espacial, até a geração da saída do modelo.

Fonte: Adaptado de Aphex34 (2015).

finais densas, ela é utilizada neste trabalho com finalidade conceitual. Seu papel é evidenciar o princípio central que fundamenta as arquiteturas exploradas nas etapas posteriores desta dissertação: a extração hierárquica de características visuais relevantes a partir da imagem bruta. Esse princípio sustenta tanto os modelos empregados para detecção e segmentação quanto aqueles voltados à extração de atributos e à predição de peso corporal.

As CNNs oferecem a capacidade de capturar relações complexas entre a morfologia visual e atributos zootécnicos de interesse, como o peso corporal. Entretanto, em cenários reais de aquisição, a imagem bruta frequentemente contém informações irrelevantes ou perturbadoras que podem comprometer o aprendizado (GOODFELLOW; BENGIO; COURVILLE, 2016). Por essa razão, neste trabalho foram escolhidos diferentes modelos para diferentes tarefas de visão computacional, cada uma cumprindo um papel específico no processamento visual.

2.1.1 Região de interesse (ROI) e controle da entrada visual

Em *pipelines* de CV, a etapa de detecção não apenas "encontra" o objeto, mas desempenha um papel estrutural ao definir a região de interesse (do inglês *Region of interest*, ROI) sobre a qual todo o processamento subsequente é ancorado (NORMAN; BISCHOFF; WEARN, 2022). Em termos práticos, a ROI corresponde ao recorte (ou máscara espacial) que contém o animal e exclui componentes de fundo (vegetação, cercas, solo, outros animais), o que estabiliza a distribuição visual que alimenta módulos posteriores como classificação, segmentação fina ou extração de descritores morfológicos (QIAO et al., 2019).

O uso de ROI também tem implicações computacionais: ao concentrar o processamento em regiões compactas, há redução de memória, de FLOPs (do inglês *Floating-Point*

Operations, ou operações de ponto flutuante, que medem o custo computacional do modelo) e de latência; o que é crucial em sistemas embarcados e aplicações de campo (LEE; KIM; LEE, 2023). Abordagens que combinam uma etapa prévia de segmentação ou agrupamento para gerar máscaras e, em seguida, aplicam detectores sobre a imagem mascarada reportam ganhos simultâneos de acurácia e eficiência, justamente por eliminar grande parte do conteúdo irrelevante antes da inferência pesada em CNNs (LEE; KIM; LEE, 2023; WANG, 2024). Dessa forma, operar sobre ROIs não é apenas uma conveniência, mas um mecanismo de controle de viés de fundo, de robustez a variações ambientais.

Uma vez localizado o animal por detecção, a segmentação semântica assume papel fundamental ao isolar a silhueta do indivíduo do fundo da cena, gerando uma máscara em nível de pixel (LONG; SHELHAMER; DARRELL, 2015). Diferentemente da detecção de objetos, que fornece apenas caixas delimitadoras aproximadas, a segmentação preserva a forma global, os contornos detalhados e características morfológicas do corpo animal, minimizando artefatos decorrentes de oclusão, variações de pose e interferências do ambiente (RONNEBERGER; FISCHER; BROX, 2015).

Entre as arquiteturas mais adequadas para essa tarefa, destaca-se a U-Net, cuja estrutura do tipo *encoder-decoder* combina extração de contexto global com recuperação precisa da informação espacial (RONNEBERGER; FISCHER; BROX, 2015). De modo geral, o ramo de contração (*encoder*) aplica sucessivas convoluções e operações de redução de resolução, produzindo mapas de características cada vez mais abstratos e semanticamente ricos. Em paralelo, o ramo de expansão (*decoder*) reconstrói progressivamente a resolução espacial da imagem, permitindo gerar uma saída densa em nível de pixel.

A Figura 2 detalha esse mecanismo. No lado esquerdo da arquitetura, observa-se o caminho de contração, no qual a imagem de entrada é transformada em mapas de características multicanais progressivamente mais profundos. Nessa etapa, a resolução espacial diminui, enquanto aumenta a capacidade da rede de representar padrões globais e relações estruturais do corpo do animal. No centro da arquitetura, a representação atinge seu maior nível de abstração, concentrando o contexto visual necessário para distinguir o animal do fundo mesmo em condições complexas de campo.

No lado direito, a figura mostra o caminho de expansão, responsável por restaurar a resolução da representação até produzir a máscara final de segmentação. Um aspecto central da U-Net, também evidenciado na figura, é o uso das conexões de atalho (*skip connections*), que copiam mapas de características do encoder e os concatenam às ativações do decoder em níveis correspondentes de resolução. Essas conexões permitem combinar informação contextual profunda com detalhes espaciais finos preservados nas camadas iniciais, favorecendo a reconstrução mais precisa dos contornos do animal e de sua silhueta.

No contexto deste trabalho, essa propriedade é particularmente importante, pois a qualidade da máscara segmentada influencia diretamente as etapas subsequentes de

extração de atributos e predição de peso corporal. Ao reduzir a presença de fundo, vegetação, cercas e outros elementos irrelevantes, a U-Net contribui para destacar características zootécnicas de interesse, como volume corporal, largura torácica e conformação geral do animal, tornando mais consistente a representação visual usada nas regressões subsequentes (MARQUES et al., 2023).

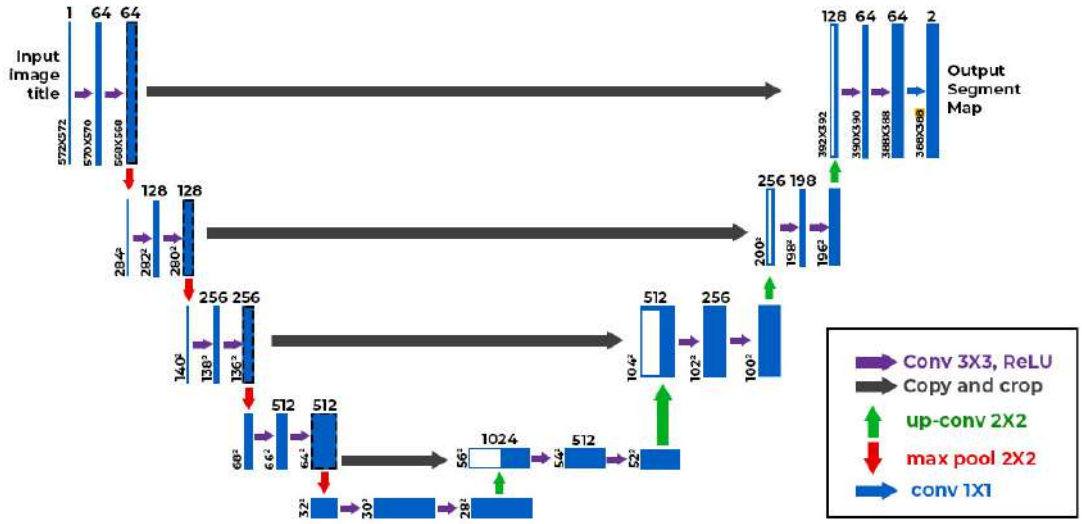


Figura 2 – Representação esquemática da arquitetura U-Net, destacando o caminho de contração (*encoder*), o caminho de expansão (*decoder*) e as conexões de atalho que combinam contexto semântico e detalhes espaciais para a geração da máscara de segmentação.

Fonte: Adaptado de Ronneberger, Fischer e Brox (2015).

2.1.2 Avaliando a qualidade da segmentação

A avaliação de segmentação é comumente realizada por métricas de sobreposição entre a máscara predita e a máscara de referência (do inglês *ground truth*). Duas medidas clássicas são o índice de Jaccard (também chamado de *Intersection over Union*, IoU) e o coeficiente Dice (HE et al., 2017).

Seja A o conjunto de píxeis preditos como pertencentes ao animal e B o conjunto de píxeis da referência. A IoU é definida pela Equação (2.1), enquanto o Dice é definido pela Equação (2.2):

$$\text{IoU}(A, B) = \frac{|A \cap B|}{|A \cup B|}, \tag{2.1}$$

$$\text{Dice}(A, B) = \frac{2|A \cap B|}{|A| + |B|}. \tag{2.2}$$

onde A representa o conjunto de píxeis da máscara predita, B é o conjunto de píxeis da máscara de referência.

A IoU possui interpretação geométrica direta ao quantificar a fração de sobreposição entre as regiões, sendo amplamente empregada também em detecção de objetos (SHI; NGAN; LI, 2014). Já o Dice é particularmente frequente em segmentação por enfatizar a concordância na área sobreposta e, na prática, apresentar maior estabilidade quando há grande predominância de fundo — condição comum em imagens de campo, nas quais a região do animal ocupa apenas parte da cena (EELBODE et al., 2020). Essas métricas fundamentam a análise quantitativa da qualidade das máscaras e permitem discutir, de forma objetiva, como a segmentação influencia as etapas subsequentes do pipeline e o desempenho da predição de peso.

A etapa subsequente consiste na extração de características profundas a partir das regiões previamente segmentadas. Nessa fase, as representações aprendidas pelas CNNs atuam como descritores visuais compactos, capazes de condensar informações morfológicas do animal em um espaço de características de alta dimensionalidade (LECUN; BENGIO; HINTON, 2015). Entre as arquiteturas voltadas à extração de atributos, as redes densamente conectadas (DenseNets) destacam-se por promoverem uma eficiente reutilização de informações entre camadas, favorecendo a propagação de gradientes e resultando em representações mais robustas e discriminativas (HUANG et al., 2017).

2.1.3 Estratégias de adaptação, regularização e validação

A aplicação de modelos de aprendizado profundo em cenários agropecuários frequentemente enfrenta o desafio da escassez de dados rotulados e da alta variabilidade ambiental. Para mitigar o risco de sobreajuste (do inglês *overfitting*, mau comportamento do modelo ao decorar os dados de treino) e garantir a capacidade de generalização dos modelos, a literatura estabelece um conjunto de práticas que abrangem desde a inicialização dos pesos até o protocolo de validação.

Uma estratégia fundamental nesse contexto é a transferência de aprendizado (do inglês *Transfer Learning*). Em vez de inicializar os pesos da rede aleatoriamente, utiliza-se um modelo pré-treinado em grandes bases de dados genéricas, como a ImageNet (DENG et al., 2009). O pressuposto teórico é que as camadas iniciais de uma CNN aprendem extratores de características de baixo nível (arestas, texturas, formas simples) que são agnósticos ao domínio, permitindo sua reutilização em tarefas específicas com conjuntos de dados menores (YOSINSKI et al., 2014). A adaptação ao novo domínio ocorre tipicamente através do ajuste fino (do inglês *fine-tuning*), onde os pesos pré-treinados são refinados, acelerando a convergência e melhorando a performance final em comparação ao treinamento do zero (PAN; YANG, 2009).

Concomitantemente à transferência de aprendizado, a técnica de aumento de dados (do inglês *Data Augmentation*) atua como um regularizador explícito. Ao aplicar transformações estocásticas — como rotações, espelhamentos, alterações de brilho e

recortes aleatórios — às imagens de treino, expande-se artificialmente a diversidade do espaço amostral (SHORTEN; KHOSHGOFTAAR, 2019). Isso é particularmente crítico em ambientes não controlados, pois força a rede a aprender características invariantes a transformações geométricas e fotométricas, simulando as variações de iluminação e pose encontradas em campo (CAMACHO-PÉREZ et al., 2022).

No que tange à otimização dos parâmetros da rede, algoritmos de gradiente descendente estocástico com taxas de aprendizado adaptativas tornaram-se o padrão na indústria. O otimizador Adam (do inglês *Adaptive Moment Estimation*), por exemplo, ajusta as taxas de aprendizado individuais para cada parâmetro com base nas estimativas do primeiro (média) e segundo (variância não centrada) momentos dos gradientes (KINGMA; BA, 2014). Essa abordagem permite lidar eficazmente com problemas de otimização em espaços de alta dimensão e com gradientes ruidosos, típicos de arquiteturas profundas complexas (GOODFELLOW; BENGIO; COURVILLE, 2016).

Por fim, a confiabilidade das métricas de desempenho pode ser aumentada adotando protocolos de validação robustos. A validação cruzada (do inglês *cross validation*, k-fold) é amplamente recomendada em cenários com conjuntos de dados limitados. Ao particionar os dados em k subconjuntos disjuntos e realizar k iterações de treinamento e teste, essa técnica reduz a variância da estimativa de erro causada pela seleção arbitrária de uma única divisão de treino-teste (KOHAVI et al., 1995). Esse procedimento oferece uma avaliação estatisticamente mais segura da capacidade de generalização do modelo diante de novos dados, essencial para a validação de ferramentas de suporte à decisão no campo.

2.2 Predição de peso animal

A biometria animal compreende técnicas para quantificação de características morfológicas e fisiológicas relevantes ao manejo zootécnico e produtivo, como peso corporal, conformação, crescimento e condição corporal (HAMADANI; GANAI, 2023). Dentre esses, o peso vivo é central, subsidiando decisões em nutrição, sanidade, reprodução e comercialização (WANG et al., 2021). Tradicionalmente, sua obtenção depende do uso de balanças ou fitas métricas e, em muitos casos, da condução do animal até um ponto específico de medição, o que requer contenção física e infraestrutura apropriada, reduzindo a frequência de monitoramento em propriedades de pequeno e médio porte (CAMACHO-PÉREZ et al., 2022).

A Figura 3 ilustra esse procedimento convencional de forma concreta. Nela, observa-se que a mensuração do peso depende de uma estrutura física dedicada de pesagem, à qual o animal precisa ser conduzido e mantido sob controle durante a operação. Esse arranjo evidencia que o processo não se resume à leitura do peso em si, mas envolve manejo, deslocamento do animal, contenção e disponibilidade de equipamento específico.

Em contextos de campo, especialmente em sistemas produtivos com infraestrutura limitada, essas exigências elevam o custo operacional, aumentam o tempo necessário para a coleta e podem intensificar o estresse animal, tornando a pesagem direta menos prática para medições frequentes.



Figura 3 – Exemplo de pesagem convencional em estrutura física dedicada, evidenciando a necessidade de condução do animal, contenção e uso de equipamento específico para obtenção do peso.

Fonte: Adaptado de Cheung (2014).

Nesse contexto, a predição do peso corporal a partir de imagens emerge como uma alternativa não invasiva, capaz de reduzir custos operacionais e mitigar o estresse animal. A premissa fundamental dessas abordagens reside na existência de correlações consistentes entre a morfologia externa do animal — expressa por dimensões corporais, proporções e silhueta — e seu peso real (WANG et al., 2021). Assim, informações visuais podem ser exploradas como indicadores indiretos para atributos zootécnicos, desde que representadas de forma adequada e analisadas por modelos computacionais capazes de capturar padrões complexos (GEBREYESUS et al., 2023).

Do ponto de vista computacional, o problema da estimativa de peso baseada em imagens pode ser formulado como uma tarefa de regressão, na qual representações visuais extraídas de imagens ou quadros de vídeo são associadas a valores contínuos correspondentes ao peso corporal (WANG et al., 2021). Esse conceito é ilustrado na Figura 4, que mostra a relação entre a imagem de um ovino e o respectivo rótulo numérico (*label*) associado ao peso, caracterizando o aprendizado a partir de pares entrada/saída.



37

Rótulo (y)

Entrada Visual (x)

Figura 4 – Representação conceitual da tarefa de regressão supervisionada: associação entre a imagem de entrada e o rótulo de peso corporal.

Fonte: Elaborado pelo autor

2.2.1 Métricas de avaliação de desempenho

Para quantificar a eficácia dos modelos de regressão na predição do peso corporal, adota-se uma abordagem combinada que avalia tanto a magnitude do erro quanto a qualidade do ajuste linear. As métricas selecionadas permitem diagnosticar diferentes aspectos do comportamento do modelo, desde sua sensibilidade a valores extremos (*outliers*) até sua capacidade de generalização.

A métrica primária para avaliação da precisão em unidades do alvo (quilogramas) é a Raiz do Erro Quadrático Médio (do inglês *Root Mean Squared Error*, RMSE). Definida pela Equação (2.3), a RMSE penaliza quadraticamente os desvios maiores, sendo, portanto, mais sensível a erros extremos (CHAI; DRAXLER, 2014).

$$\text{RMSE} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}. \tag{2.3}$$

onde n é o número total de amostras, y_i é o valor real (observado) da i-ésima amostra e $\hat{y}_i$ é o valor predito pelo modelo para a mesma amostra.

Em complemento, o Erro Absoluto Médio (do inglês *Mean Absolute Error*, MAE), apresentado na Equação (2.4), oferece uma interpretação direta da magnitude média do erro esperado (WILLMOTT; MATSUURA, 2005). Por tratar todos os desvios com o mesmo peso (norma L_1), a MAE é considerada uma medida mais robusta e natural para reportar a acurácia média do sistema em termos práticos para o produtor.

$$\text{MAE} = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y}_i|. \tag{2.4}$$

Para avaliar a *bondade de ajuste* (*goodness-of-fit*) e a capacidade explicativa do modelo, utilizam-se o Coeficiente de Determinação (R^2) e o Coeficiente de Correlação de Pearson (r). O R^2, definido pela Equação (2.5), indica a proporção da variância da variável dependente que é previsível a partir da variável independente, sendo um indicador adimensional de qualidade global do modelo (CHICCO; WARRENS; JURMAN, 2021):

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2}. \tag{2.5}$$

em que $\bar{y}$ representa a média dos valores reais da variável dependente.

Embora alta correlação não implique necessariamente baixo erro absoluto (visto que um modelo pode ter viés sistemático e ainda assim apresentar alto r), a análise conjunta dessas métricas fornece um panorama geral para a validação da ferramenta proposta.

2.3 Sistemas computacionais aplicados ao ambiente rural

O desenvolvimento de sistemas computacionais voltados ao ambiente rural enfrenta restrições específicas, substancialmente distintas daquelas observadas em contextos urbanos ou laboratoriais controlados (Walsh Medical Media, 2023). Em propriedades de pequeno e médio porte, predominantes na agricultura familiar brasileira, são frequentes limitações de infraestrutura, conectividade intermitente, heterogeneidade de dispositivos disponíveis e diferentes níveis de alfabetização digital entre os usuários, fatores que impactam diretamente o projeto e a adoção de soluções computacionais para o manejo zootécnico (MAPA, 2025). Soma-se a esse cenário a diversidade dos ambientes de criação, que podem incluir currais cobertos, áreas abertas, instalações improvisadas ou estruturas permanentes, cada qual impondo condições operacionais distintas, como variações de iluminação, exposição à poeira, interferências ambientais e restrições físicas ao uso de equipamentos eletrônicos.

A Figura 5 evidencia de forma concreta a heterogeneidade dos cenários de coleta considerados neste trabalho. Em (a), observa-se um curral externo com elevada concentração de animais, cercamento rústico e forte incidência de luz natural. Em (b), também se vê um ambiente externo, porém com configuração espacial distinta, maior profundidade de cena e diferente distribuição de sombra e visibilidade. Em (c), a coleta ocorre em instalação coberta, marcada pela presença de cochos, pilares centrais e menor uniformidade luminosa. Já em (d), observa-se outro ambiente coberto, mais alongado e compartimentado, com disposição diferente dos animais e da infraestrutura de manejo. Em conjunto, essas imagens mostram que a aquisição de dados não se dá em um espaço homogêneo ou rigidamente controlado, mas em contextos que variam quanto à infraestrutura, ao tipo de instalação, ao grau de abertura do ambiente, à iluminação, à organização espacial e à presença de elementos estruturais no entorno.

Essa diversidade de condições tem implicações diretas para o projeto da solução computacional. Variações de iluminação, oclusão entre animais, profundidade de cena, contraste com o fundo e organização física do espaço afetam tanto a qualidade das imagens capturadas quanto o desempenho dos métodos de processamento e análise. Desse modo, a heterogeneidade ilustrada na Figura 5 não constitui apenas uma característica descritiva

do ambiente rural, mas um requisito central de projeto. Em vez de depender de condições rígidas de captura ou de infraestrutura padronizada, a solução proposta deve ser capaz de tolerar mudanças de contexto, operar em diferentes arranjos de manejo e preservar sua utilidade prática mesmo em ambientes não controlados. Essa perspectiva justifica decisões arquiteturais orientadas à robustez, à portabilidade e à simplicidade operacional, de modo a favorecer a adoção do sistema em situações reais de uso.



(a) (b)

(c) (d)

Figura 5 – Exemplos de cenários reais e não padronizados de coleta em ambiente rural: (a) curral externo com alta densidade de animais; (b) curral externo com configuração espacial distinta; (c) instalação coberta com cochos e pilares centrais; (d) instalação coberta alongada com organização diferente do manejo.

Fonte: Elaborado pelo autor.

Outro aspecto crítico associado a esse contexto é a conectividade intermitente, que

representa um dos principais entraves à informatização do manejo animal em ambientes rurais brasileiros, especialmente na agricultura familiar. Em muitas localidades, o acesso à rede é inexistente, instável ou disponível apenas em momentos específicos, o que inviabiliza soluções dependentes de comunicação contínua com serviços remotos (SILVA, 2024). Nesses cenários, o sistema precisa manter sua operação de forma autônoma por longos períodos, com armazenamento local dos dados produzidos em campo e sincronização realizada posteriormente, quando houver condições adequadas de conectividade. Assim, além de lidar com a variabilidade física e operacional dos ambientes de coleta, a arquitetura da solução deve também responder às restrições concretas de infraestrutura digital presentes no contexto rural.

Nesse contexto, abordagens baseadas no princípio *local-first* emergem como uma estratégia conceitualmente adequada para aplicações em campo. Diferentemente de arquiteturas centradas exclusivamente na nuvem, sistemas *local-first* priorizam a execução local das funcionalidades essenciais, garantindo que a coleta, o processamento inicial e o armazenamento dos dados ocorram diretamente no dispositivo utilizado em campo (KLEPPMANN et al., 2019). A sincronização com serviços remotos passa a desempenhar um papel complementar, voltado à consolidação dos dados, à integração entre diferentes usuários ou à realização de análises em nível agregado. A Figura 6 ilustra, de forma conceitual, o funcionamento desse paradigma, destacando a autonomia operacional local e a sincronização eventual com a infraestrutura central.

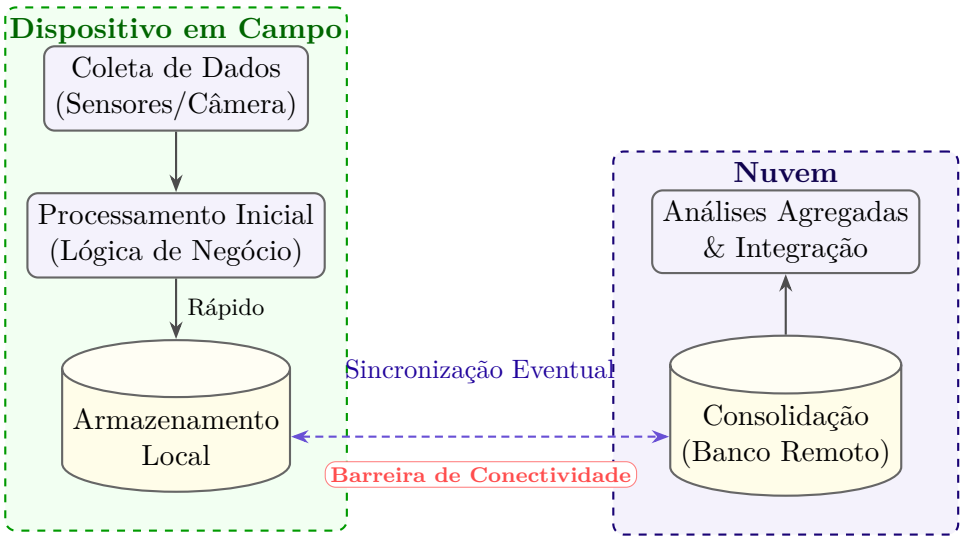


Figura 6 – Arquitetura conceitual *Local-First* aplicada.

Fonte: Elaborado pelo autor.

2.4 Avaliação da qualidade de software e usabilidade

A validação de soluções tecnológicas aplicadas ao agronegócio exige uma abordagem multidimensional que contemple tanto a robustez interna do artefato de software quanto sua aceitação pelo usuário final. Esta seção fundamenta as métricas adotadas para aferir a manutenibilidade do código-fonte e a usabilidade percebida do sistema proposto.

2.4.1 Usabilidade e a escala SUS

A usabilidade não é uma propriedade intrínseca do software, mas sim uma qualidade da interação entre o usuário, o sistema e a tarefa. Conforme a norma ISO 9241-11, a usabilidade é definida pela medida em que um produto pode ser usado por usuários específicos para alcançar objetivos específicos com eficácia, eficiência e satisfação em um contexto de uso especificado (INTERNATIONAL ORGANIZATION FOR STANDARDIZATION, 2018). No contexto da extensão rural e da agricultura de precisão, essa definição torna-se crítica, visto que a heterogeneidade no letramento digital dos produtores pode erguer barreiras à adoção tecnológica (BANGOR; KORTUM; MILLER, 2008b).

Para quantificar a usabilidade subjetiva, a Escala de usabilidade de sistemas (do inglês *System Usability Scale*, SUS) consolidou-se como o padrão da indústria por sua robustez psicométrica e neutralidade tecnológica. O instrumento consiste em um questionário de dez itens com respostas em escala Likert de cinco pontos, alternando entre afirmações positivas e negativas para mitigar vieses de resposta (BROOKE et al., 1996). O escore final do SUS varia de 0 a 100, onde pontuações acima de 68 são tipicamente consideradas acima da média, e valores superiores a 80 indicam excelência em usabilidade (SAURO, 2011). A aplicação do SUS neste trabalho visa identificar gargalos na interação humano-computador que possam comprometer a operabilidade do sistema em campo.

2.4.2 Métricas estáticas de manutenibilidade

A análise estática permite inferir a qualidade interna do sistema através de indicadores quantitativos, sem a necessidade de execução do programa.

Embora controversa quando analisada isoladamente, a contagem de Linhas de Código (do inglês *Lines of Code*, LOC) serve como uma medida de magnitude do sistema e, indiretamente, do esforço cognitivo necessário para sua compreensão. Contudo, métricas estruturais oferecem diagnósticos mais precisos sobre o risco de defeitos.

A Complexidade Ciclomática (do inglês *Cyclomatic Complexity*, CC), fundamentada na teoria dos grafos, mensura a complexidade lógica de um módulo de software. Seja G o grafo de fluxo de controle do módulo sob análise; sua complexidade ciclomática, denotada por $v(G)$, corresponde ao número de caminhos linearmente independentes nesse grafo.

Conforme McCabe (1976), essa métrica é expressa por:

$$v(G) = E - N + 2P. \tag{2.6}$$

em que G representa o grafo de fluxo de controle, $v(G)$ denota a complexidade ciclomática associada a esse grafo, E é o número de arestas, N é o número de nós e P é o número de componentes conectados. Módulos com alta complexidade ciclomática ($v(G) > 10$) correlacionam-se fortemente com maior densidade de erros e maior dificuldade de teste, indicando áreas prioritárias para refatoração (MCCABE, 1976).

Para uma visão holística, utiliza-se o Índice de Manutenibilidade (do inglês *Maintainability Index*, MI). O MI é uma métrica composta que integra a CC, o volume de Halstead (que considera o vocabulário de operadores e operandos) e o LOC em um único valor polinomial (OMAN; HAGEMEISTER, 1992a). Originalmente calibrado para indicar a facilidade de manutenção, valores de MI abaixo de 65 sugerem código de difícil manutenção, enquanto valores acima de 85 indicam alta manutenibilidade (WELKER, 2001). A monitoração desses índices assegura que a complexidade técnica do sistema não inviabilize sua continuidade como produto.

3 Estado da Arte

Estudos recentes têm investigado diversas abordagens que combinam visão computacional e aprendizado de máquina para a estimativa do peso de ovinos e caprinos. Essas pesquisas exploram diferentes técnicas e metodologias, cada uma contribuindo com avanços específicos, mas também enfrentando limitações técnicas e operacionais. A Tabela 1 apresenta um resumo comparativo dos principais trabalhos encontrados na literatura, destacando amostras, métodos e métricas.

Autor (Ano)	**Animais**	**Técnicas**	**Métrica principal**
(MENESATTI et al., 2014)	27	Estereovisão 3D; regressão	$R^2 = 0{,}79$
(SANT'ANA et al., 2021)	32	Extração manual de atributos; RF; SVM	$R^2 = 0{,}687$ (RF)
(SAMPERIO et al., 2021)	64	Intel RealSense D435; regressão linear	$R^2 = 0{,}86$
(CAMACHO-PÉREZ et al., 2022)	56	Kinect; modelo polinomial; GA; CSA	RMSE 7,55% (CSA)
(HE et al., 2023)	n/r	RGB-D; CNN	MAE = 6,73 kg; MAPE = 14,6%

n/r: não reportado.

Tabela 1 – Resumo dos principais estudos sobre predição de peso em pequenos ruminantes.

Fonte: Elaborado pelo autor.

Menesatti et al. (2014) propuseram um sistema de estereovisão com câmeras de baixo custo para capturar imagens tridimensionais (3D) e extrair medidas morfométricas de 27 ovelhas. Embora o método tenha alcançado resultados consideráveis em comparação com a literatura ($R^2 = 0{,}79$), sua aplicação prática é limitada pela exigência de posicionamento controlado dos animais em ambiente estático, o que demanda estruturas de contenção e condições de manejo nem sempre disponíveis em propriedades de pequeno e médio porte.

De forma semelhante, Sant'Ana et al. (2021) utilizaram vídeos de 32 ovinos para extrair manualmente características morfológicas e aplicar modelos de aprendizado supervisionado, incluindo *Random Forest* (RF) e *Support Vector Machine* (SVM). O melhor desempenho foi observado com o RF ($R^2 = 0{,}687$). No entanto, a necessidade de segmentação manual das imagens, aliada ao tamanho reduzido e à homogeneidade do conjunto de dados, compromete a escalabilidade e a capacidade de generalização dos modelos para diferentes raças, idades e sistemas de produção.

No trabalho de Samperio et al. (2021), imagens capturadas em visão superior (*top-view*), obtidas com uma câmera *Intel RealSense D435*, foram utilizadas para estimar o peso de 272 cordeiros por meio de regressão linear, resultando em $R^2 = 0{,}86$. Embora

esse valor indique elevada correlação entre as medidas extraídas e o peso real, o método exige o isolamento individual do animal e apresenta sensibilidade a variações ambientais, fatores que reduzem sua robustez em condições de campo não controladas.

Já Camacho-Pérez et al. (2022) empregaram um sensor *Kinect* para adquirir parâmetros biométricos de 56 ovelhas Pelibuey, ajustados a um modelo polinomial cujo grau foi determinado por algoritmos meta-heurísticos — *Genetic Algorithm* (GA) e *Cuckoo Search Algorithm* (CSA). Os autores reportaram erro quadrático médio (RMSE, do inglês *Root Mean Square Error*) de 7,68% para o GA e 7,55% para o CSA, com desempenho semelhante entre os métodos. As aquisições ocorreram sob cobertura, com os animais posicionados entre 1,2 e 1,8 m do sensor, lateralmente a cerca de 1,5 m. Movimentos bruscos geraram *outliers* com erros de predição superiores a 25%. Com base nesses resultados, os próprios autores recomendam ampliar a base de dados, utilizar hardware mais potente e empregar sistemas de aquisição fixos, de modo a reduzir erros e viabilizar aplicações embarcadas.

Por sua vez, He et al. (2023) investigaram a utilização de imagens de cor e profundidade (RGB-D) combinadas com redes neurais convolucionais CNNs para estimar o peso de ovinos. O estudo reportou um erro absoluto médio (MAE, do inglês *Mean Absolute Error*) de 6,73 kg e um erro percentual absoluto médio (MAPE, do inglês *Mean Absolute Percentage Error*) de 14,6%. Apesar da adoção de técnicas avançadas, o modelo mostrou-se sensível à postura dos animais e às condições de iluminação, o que dificulta sua aplicação em tempo real.

Apesar das contribuições relevantes da literatura, observa-se uma lacuna crítica no que se refere à transposição dos modelos de predição para sistemas produtivos reais. A maioria dos trabalhos permanece restrita ao âmbito experimental, frequentemente dependente de ambientes controlados, operadores especializados ou infraestrutura laboratorial específica. Além disso, são escassas as soluções que integram todo o fluxo computacional — desde a captura automatizada das imagens até a inferência do peso — em uma ferramenta única.

Diante desse cenário, o presente trabalho propõe uma abordagem unificada que integra técnicas de visão computacional e aprendizado de máquina em uma ferramenta prática para detecção e predição automática do peso de pequenos ruminantes. A solução é desenvolvida com foco na acessibilidade tecnológica, robustez em condições de campo e viabilidade operacional, de modo a favorecer a adoção de tecnologias inteligentes e a democratização da pecuária de precisão.

4 Modelo de Visão Computacional para Estimativa de Peso

Este capítulo descreve a metodologia adotada para o desenvolvimento e validação do sistema proposto, estruturando de forma sistemática as etapas que compõem o pipeline completo de aquisição, processamento e disponibilização das estimativas de peso.

A abordagem metodológica foi organizada segundo uma lógica sequencial, na qual cada componente do sistema desempenha um papel dentro de um fluxo integrado. Parte-se da aquisição orientada a eventos no ambiente de campo, seguida pelas etapas de detecção do animal, segmentação da silhueta corporal, extração e agregação de características visuais, estimação do peso por regressão e, por fim, associação do resultado ao identificador individual.

A Figura 7 apresenta o fluxograma geral da metodologia adotada.

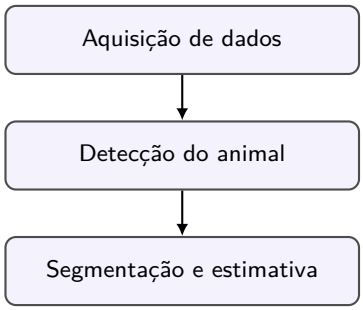


Figura 7 – Fluxograma da metodologia proposta.
Fonte: Elaborado pelo autor.

A organização deste capítulo reflete a estrutura metodológica apresentada. A Seção 4.1 descreve o Sistema de Captura, detalhando a infraestrutura embarcada responsável pela aquisição dos dados e pelo controle do evento de passagem do animal. Na sequência, a Seção 4.2 apresenta os fundamentos e procedimentos da etapa de Detecção, enquanto a Seção 4.3 aborda a Segmentação e a Estimativa de peso, contemplando o processamento visual e a modelagem preditiva.

4.1 Aquisição de dados

A aquisição das imagens ocorre durante a passagem do animal por uma estrutura de contenção construída com tubos metálicos do tipo metalon, medindo 65 × 36 cm. Essa estrutura orienta o deslocamento sequencial dos animais.

O conjunto experimental foi composto por 99 animais distintos, cada um registrado em um único vídeo, totalizando 99 vídeos coletados em dois locais diferentes de captura. Cada vídeo contém exclusivamente um animal por vez, evitando sobreposição de indivíduos e ambiguidade na associação das informações biométricas. As gravações foram realizadas com taxa de 30 quadros por segundo (30 fps), em resolução Full HD (1920 × 1080 pixels), utilizando uma câmera RGB convencional. A câmera foi posicionada no topo da estrutura metálica, orientada verticalmente para baixo, de modo a capturar a região dorsal do animal durante sua passagem pela plataforma.

A câmera é acoplada diretamente a um dispositivo embarcado, responsável pelo processamento local do fluxo de vídeo. Essa arquitetura elimina a dependência de um computador *host* externo e favorece a operação em campo, como mostra a Figura 8.

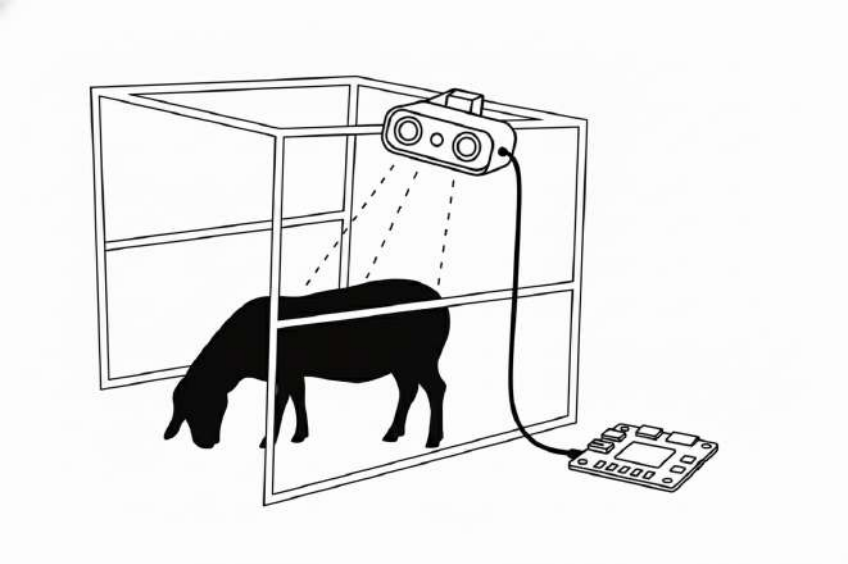


Figura 8 – Esquema do posicionamento da câmera em relação ao animal.
Fonte: Elaborado pelo autor.

Embora a captura nativa tenha sido realizada em resoluções maiores, para os experimentos de segmentação e estimação de peso as imagens foram redimensionadas em 1024 × 1024, 512 × 512 e 256 × 256 pixels. Essa estratégia permitiu analisar o impacto da escala espacial no desempenho dos modelos e no custo computacional exigido.

O processo de rotulação dos dados envolveu três etapas complementares. Primeiramente, o peso real foi obtido manualmente por meio de balança suspensa, operada por técnicos treinados, imediatamente após a captura do vídeo. A pesagem seguiu procedimentos padronizados de manejo para pequenos ruminantes, priorizando estabilidade do animal e redução de movimentações excessivas durante a leitura, cada registro foi associado ao identificador individual do animal, garantindo correspondência entre vídeo e medida de referência. A Figura 9 ilustra o procedimento de pesagem adotado durante a coleta.

Em segundo lugar, para o treinamento do modelo de segmentação, foram construídas



Figura 9 – Procedimento de aferição manual do peso utilizando balança suspensa.
Fonte: Elaborado pelo autor.

máscaras binárias manuais a partir de quadros selecionados dos vídeos, isolando a silhueta do animal em relação ao fundo. Essas máscaras foram elaboradas de forma supervisionada, delimitando pixel a pixel a região correspondente ao corpo do animal. A Figura 10 apresenta um exemplo representativo de máscara binária gerada no processo de rotulação.

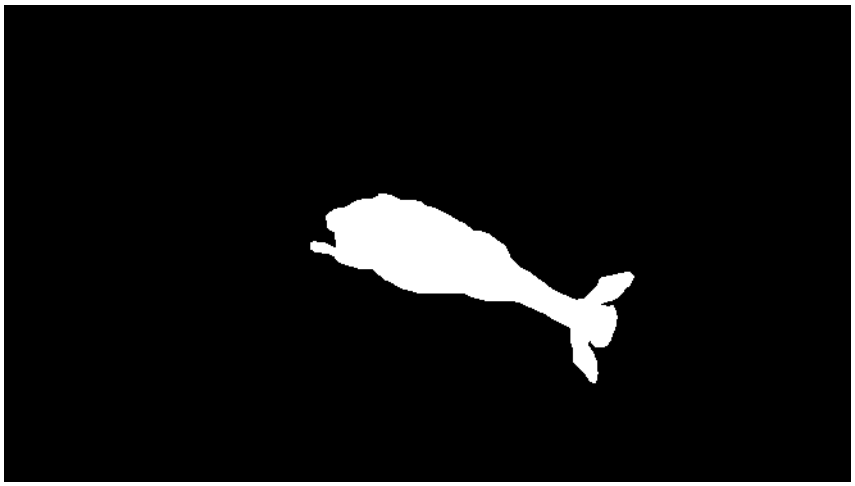


Figura 10 – Exemplo de máscara binária.
Fonte: Elaborado pelo autor.

A organização do processo de aquisição descrita nesta seção estabelece a correspondência entre vídeo, identificador individual e peso aferido manualmente, formando o conjunto de dados utilizado nos experimentos subsequentes. A padronização do enquadramento da câmera, da taxa de captura e do procedimento de pesagem define as condições sob as quais os dados foram coletados. Com base nessa estrutura, as próximas seções detalham as etapas de processamento computacional aplicadas aos registros obtidos.

4.2 Detecção

Para viabilizar a operação autônoma do dispositivo embarcado, tornou-se necessário implementar um mecanismo capaz de decidir automaticamente quando iniciar e quando encerrar a gravação associada à passagem de cada animal. Como o sistema opera de forma contínua em campo, a gravação permanente do fluxo de vídeo foi descartada devido ao alto consumo de armazenamento e processamento.

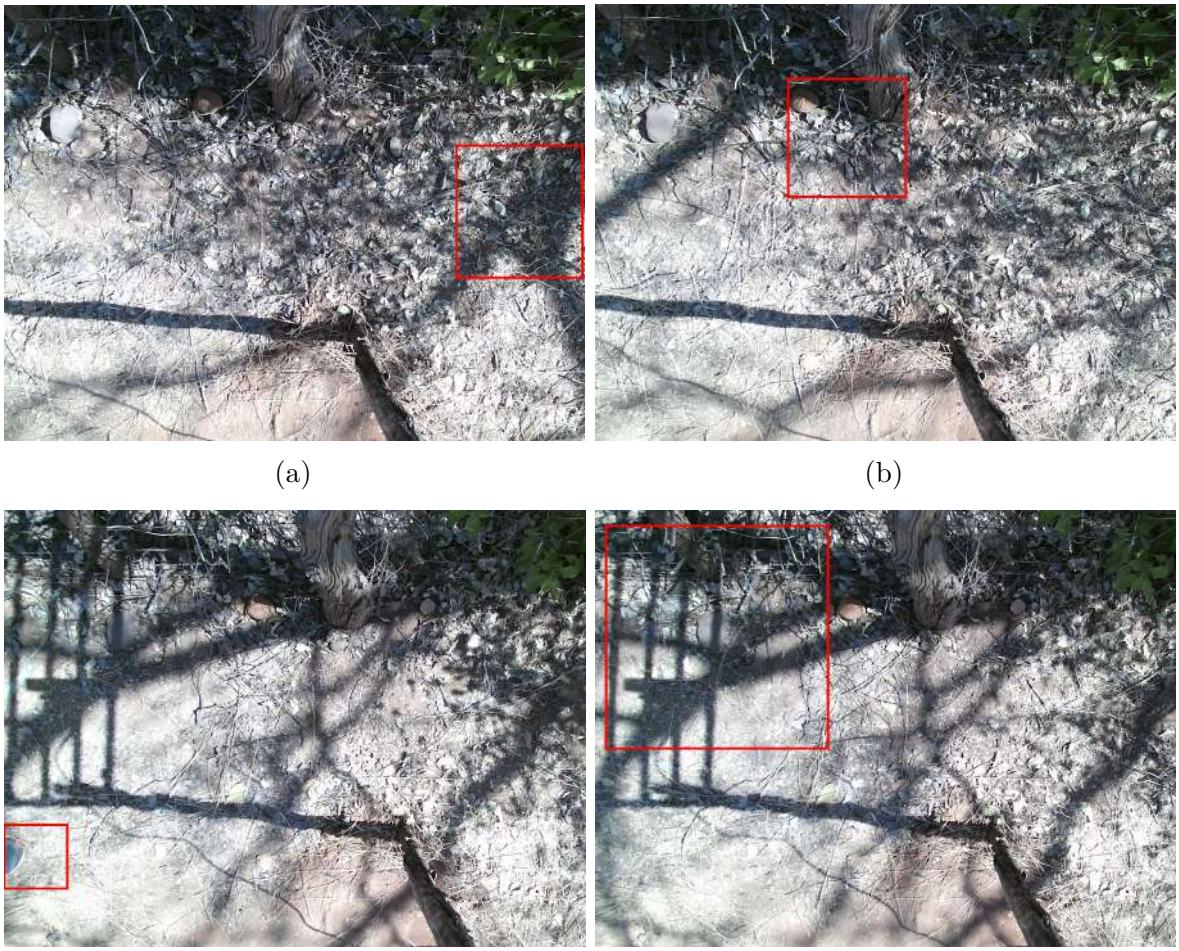
O problema metodológico consistiu, portanto, em definir um critério computacional para identificar o momento em que o animal encontra-se adequadamente posicionado na plataforma de captura, acionando o início do evento, e determinar quando sua passagem foi concluída, encerrando a aquisição.

Inicialmente, foi avaliada uma abordagem baseada em detecção de movimento por subtração de fundo. Essa estratégia utiliza modelagem do fundo estático e identificação de regiões em movimento a partir da diferença entre frames consecutivos (MALLICK, 2015).

Durante os testes realizados, observou-se que a técnica apresentou instabilidade operacional em virtude de variações de iluminação natural, sombras projetadas pela estrutura metálica da contenção e pequenas oscilações da câmera. Esses fatores produziram ativações espúrias do mecanismo de captura, mesmo na ausência de um animal completamente posicionado na plataforma. A Figura 11 apresenta quatro exemplos de ativações espúrias observadas durante os testes com subtração de fundo. Em (a), nota-se a detecção indevida de uma região do solo, sem correspondência com o corpo do animal. Em (b), a ativação ocorre em uma área próxima à vegetação e à base da estrutura, sugerindo influência de textura e contraste local. Em (c), observa-se uma pequena ativação periférica, indicando sensibilidade do método a ruídos nas bordas da imagem. Por fim, em (d), a região destacada abrange uma área mais extensa associada principalmente a sombras e elementos estruturais do cenário. Em todos os casos, os retângulos vermelhos indicam regiões classificadas como movimento relevante, embora não correspondam ao animal, o que evidencia a limitação do critério de acionamento baseado exclusivamente em variação de píxeis em ambientes reais de captura.

Diante dessas limitações observadas experimentalmente, optou-se por uma abordagem baseada em detecção explícita do objeto de interesse. O sistema utiliza um modelo de detecção pré-treinado (JOCHER; QIU; CHAURASIA, 2023) para identificar a classe correspondente ao animal. A cada frame processado, o modelo retorna a caixa delimitadora (*bounding box*) associada à detecção com maior confiança.

Para evitar que a captura fosse acionada prematuramente — por exemplo, quando o animal ainda não estivesse completamente posicionado na região útil da imagem — foi definida uma região de interesse (ROI) fixa, correspondente à área central da plataforma de pesagem.



(a) (b)

(c) (d)

Figura 11 – Exemplos de ativações espúrias na etapa de detecção por subtração de fundo: (a) solo; (b) vegetação/base da estrutura; (c) ruído periférico; (d) sombra e elementos estruturais.

Fonte: Elaborado pelo autor.

Como critério de ativação do evento, seja b a caixa delimitadora retornada pelo detector e r a região de interesse previamente definida. A interseção entre ambas é calculada por meio da métrica IoU

A ativação do evento de captura é modelada como uma função condicional sobre o valor da IoU. Seja θ_{IoU} um limiar definido empiricamente. Define-se a variável de ativação A_t no instante t como:

$$A_t = \begin{cases} 1, & \text{se IoU}(b_t, r) \geq \theta_{\text{IoU}}, \\ 0, & \text{caso contrário.} \end{cases} \tag{4.1}$$

Conforme definido na Equação 4.1, o início do evento de captura ocorre quando $A_t = 1$, isto é, quando a sobreposição entre a caixa detectada e a região de interesse atinge ou supera o limiar estabelecido.

Uma vez satisfeita essa condição, o sistema passa a armazenar o *frame* corrente e os subsequentes. O encerramento do evento é determinado quando a condição $A_t = 1$ deixa de ser satisfeita por X frames consecutivos, parâmetro ajustado empiricamente para evitar oscilações decorrentes de pequenas variações na detecção.

Essa lógica caracteriza um mecanismo determinístico de ativação por presença qualificada, no qual a gravação é condicionada ao correto posicionamento espacial do objeto na área útil da plataforma.

4.3 Segmentação e estimativa

A etapa de segmentação foi introduzida com o objetivo de reduzir a interferência do fundo e de elementos estruturais da plataforma de captura na extração das características visuais. Como o ambiente de aquisição apresenta variações de iluminação, estruturas metálicas e presença de múltiplos objetos no enquadramento, a utilização direta do *frame* completo poderia induzir o modelo a aprender padrões não relacionados à morfologia do animal. Assim, a segmentação semântica foi empregada para isolar a silhueta corporal, restringindo o processo subsequente de extração de atributos às regiões efetivamente relevantes para a estimativa de peso.

Para avaliar essa hipótese, foram conduzidas baterias de experimentos comparativos contemplando diferentes estratégias arquiteturais, tanto com quanto sem segmentação prévia. No contexto da segmentação, foram testadas variações da U-Net (RONNEBERGER; FISCHER; BROX, 2015), bem como arquiteturas derivadas, incluindo U-Net++ (ZHOU et al., 2019), FPN (LIN et al., 2017) e versões com *backbones* distintos, tais como EfficientNet-B7 (TAN; LE, 2019) e MiT-B5 (XIE et al., 2021).

Na etapa de extração de características profundas, foram avaliadas sistematicamente múltiplas redes convolucionais pré-treinadas, incluindo Xception (CHOLLET, 2017), VGG16 e VGG19 (SIMONYAN; ZISSERMAN, 2015), ResNet (50, 101 e 152, incluindo versões V2) (HE et al., 2016), InceptionV3 (SZEGEDY et al., 2016), InceptionResNetV2 (SZEGEDY et al., 2017), MobileNet (V1 e V2) (HOWARD et al., 2017; SANDLER et al., 2018), DenseNet (121, 169 e 201) (HUANG et al., 2017) e EfficientNet (B0 a B7) (TAN; LE, 2019). Para cada arquitetura, foram analisadas métricas de desempenho preditivo.

Com base nesses resultados, adotou-se a seguinte estratégia final: os *frames* extraídos do vídeo são inicialmente submetidos ao modelo de segmentação, produzindo uma máscara binária que preserva apenas a silhueta do animal. Na sequência, cada *frame* segmentado é submetido à DenseNet-169 (HUANG et al., 2018) para extração automática de características profundas. Para cada animal, as representações extraídas ao longo dos *frames* são agregadas por meio da média dos vetores gerados, conforme a Equação 4.2, resultando em um único vetor representativo da amostra:

$$\bar{\mathbf{v}} = \frac{1}{n} \sum_{i=1}^{n} \mathbf{v}_i \tag{4.2}$$

onde $\mathbf{v}_i$ é o vetor de características extraído do i-ésimo *frame*; n é o número total de *frames*; e $\bar{\mathbf{v}}$ representa o vetor médio associado ao animal.

O vetor agregado foi então utilizado como entrada para modelos supervisionados de regressão, com o objetivo de estimar o peso do animal a partir das características visuais extraídas. Cada modelo foi treinado e validado sob o mesmo protocolo experimental, permitindo comparação direta de desempenho. A regressão linear simples foi mantida como referência, servindo como referência interpretável para análise dos ganhos obtidos com modelos mais complexos.

A Figura 12 apresenta o fluxo completo do processo, ilustrando a agregação dos vetores e a etapa de regressão para o caso de um animal com quatro *frames*.

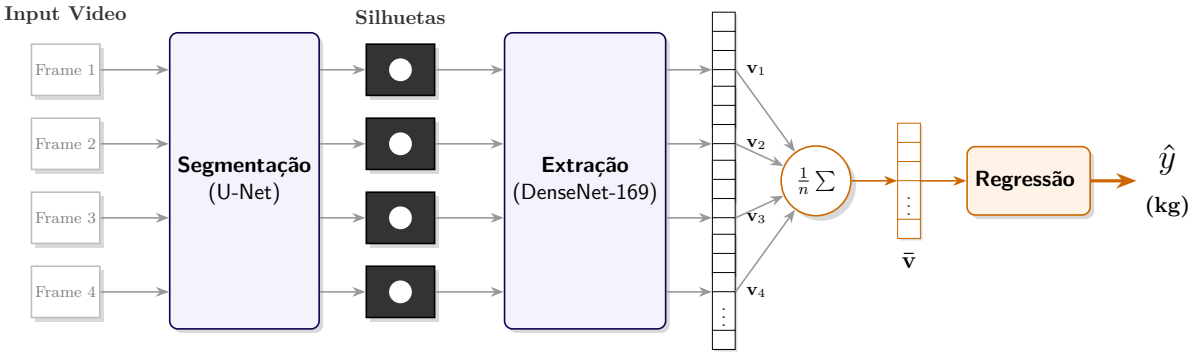


Figura 12 – Pipeline proposto para estimativa de peso. Os frames são segmentados individualmente, processados pela CNN e agregados via média antes da regressão.

Fonte: Elaborado pelo autor.

5 Sistema Proposto

O sistema proposto foi concebido para operar em um contexto caracterizado por restrições estruturais típicas da produção rural extensiva, especialmente no que se refere à conectividade intermitente, ao isolamento geográfico das propriedades e à necessidade de robustez operacional em campo. A solução foi estruturada em dois ambientes operacionais complementares: (i) o ambiente de coleta em campo e (ii) o ambiente de nuvem para consolidação e persistência de dados.

No ambiente de coleta, não se pressupõe disponibilidade contínua de acesso à internet. Assim, todos os dados gerados durante as sessões de pesagem são persistidos localmente no dispositivo móvel, garantindo autonomia operacional. A interoperabilidade entre os componentes embarcados e o aplicativo cliente constitui requisito central da arquitetura, uma vez que o processamento das imagens e a inferência dos modelos de visão computacional ocorrem em um dispositivo embarcado fisicamente acoplado à estrutura de contenção dos animais.

O dispositivo embarcado integra os modelos de detecção de movimento, segmentação e predição de peso descritos nas seções anteriores. Esse equipamento conecta-se a uma câmera responsável pela captura do fluxo de vídeo e a um dispositivo de identificação individual dos animais. Uma vez processadas as informações, o identificador do animal e o peso estimado são transmitidos, via rede local, ao aplicativo móvel cliente. O aplicativo, por sua vez, atua como interface de interação com o usuário, realizando o armazenamento local dos dados e exibindo as informações em tempo real durante a sessão de coleta.

No ambiente de nuvem, a sincronização dos dados ocorre de forma eventual, quando há disponibilidade de conectividade. A Figura 13 resume a disposição geral da solução proposta.

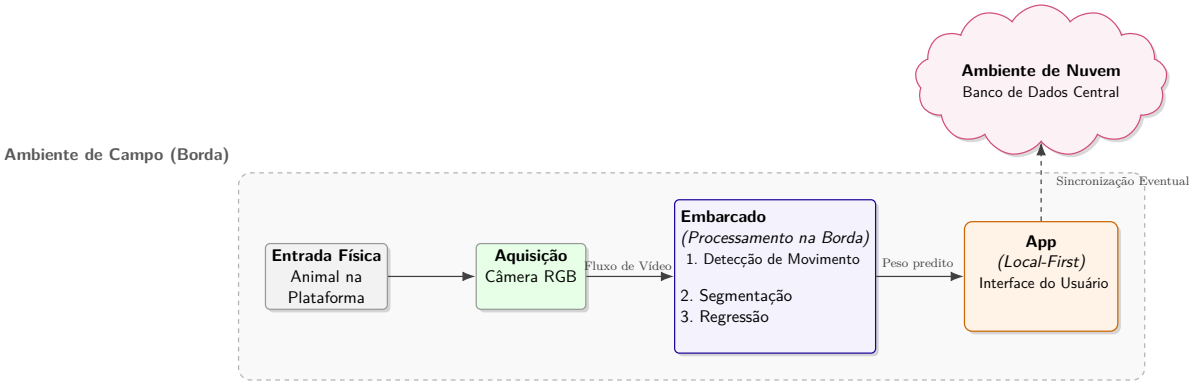


Figura 13 – Arquitetura do sistema proposto.

Fonte: Elaborado pelo autor.

A partir dessa arquitetura, foram elicitados os requisitos funcionais e não funcionais que orientaram a modelagem e implementação do sistema.

5.0.1 Elicitação de requisitos

Os requisitos funcionais, definidos na Tabela 2, definem as funcionalidades esperadas do sistema, isto é, o que ele deve realizar para atender aos objetivos propostos. Os requisitos não funcionais, definidos na Tabela 3, dizem respeito a atributos de qualidade, desempenho, confiabilidade e usabilidade, essenciais para garantir a eficiência e a adoção prática da solução no contexto rural.

ID	Descrição
RF-01	Cadastro de usuários no sistema.
RF-02	Autenticação de usuários previamente cadastrados.
RF-03	Realização de coleta manual de dados biométricos dos animais.
RF-04	Realização sessões de coleta automática de peso
RF-05	Manter um histórico das sessões de coleta realizadas no dispositivo.
RF-06	Permitir a sincronização com o servidor remoto

Tabela 2 – Requisitos funcionais.

Fonte: Elaborado pelo autor.

ID	Descrição
RNF-01	Operar sem necessidade de internet.
RNF-02	Possuir interface acessível e intuitiva.
RNF-03	Ser compatível com dispositivos móveis Android e iOS.

Tabela 3 – Requisitos não funcionais.

Fonte: Elaborado pelo autor.

5.0.2 Modelagem

Com base nos requisitos previamente definidos, a modelagem do sistema foi formalizada por meio da linguagem UML (OBJECT MANAGEMENT GROUP, 2017) — do inglês, *Unified Modeling Language* —, utilizando diferentes diagramas para representar aspectos estruturais e comportamentais da aplicação.

A construção do sistema seguiu uma abordagem *straightforward*, priorizando a automação do processo de pesagem e a mínima necessidade de intervenção por parte do usuário. Na versão inicial do sistema, concebida como um Produto Mínimo Viável (MVP), o ator principal — o usuário — interage com a aplicação por meio de quatro funcionalidades principais, estruturadas de forma modular no aplicativo móvel.

A coleta manual de dados constitui a primeira funcionalidade do sistema e foi projetada para cenários em que a automação completa não é possível ou necessária. Nessa funcionalidade, o usuário seleciona manualmente os animais cadastrados e registra suas medições biométricas por meio da interface do aplicativo. Os dados inseridos são armazenados localmente no dispositivo, permitindo a operação do sistema de forma independente de conectividade com a internet, o que atende às limitações frequentes do ambiente rural.

A coleta automática de dados representa a funcionalidade central da solução proposta. Por meio dela, o usuário configura sessões de coleta informando parâmetros como data, propriedade e lote, além de realizar a sincronização com o dispositivo de captura. Durante a sessão ativa, o sistema opera de forma contínua, exibindo em tempo real os animais identificados e seus respectivos pesos estimados, mantendo o controle do número de capturas realizadas. Essa funcionalidade foi concebida para reduzir ao máximo a intervenção humana no processo de pesagem, aumentando a eficiência e a padronização da coleta.

A gestão de animais corresponde à funcionalidade responsável por permitir ao usuário visualizar e consultar informações individuais dos animais cadastrados no sistema. Por meio dessa funcionalidade, é possível acessar dados básicos associados a cada animal, servindo como suporte tanto para as coletas manuais quanto para as automáticas. Essa organização facilita a identificação dos indivíduos durante o manejo e contribui para a consistência dos registros biométricos ao longo do tempo.

Por fim, a funcionalidade de histórico de coletas permite ao usuário acompanhar as sessões de coleta já realizadas. Nessa interface, são apresentados registros contendo informações como data da sessão, propriedade, lote, quantidade de animais capturados e o estado da sincronização dos dados. Essa funcionalidade fornece uma visão consolidada das operações realizadas, permitindo a rastreabilidade das medições e apoiando análises posteriores, mesmo quando os dados ainda não foram enviados para um sistema central.

A Figura 14 ilustra graficamente essas interações, por meio do Diagrama de Casos de Uso do sistema.

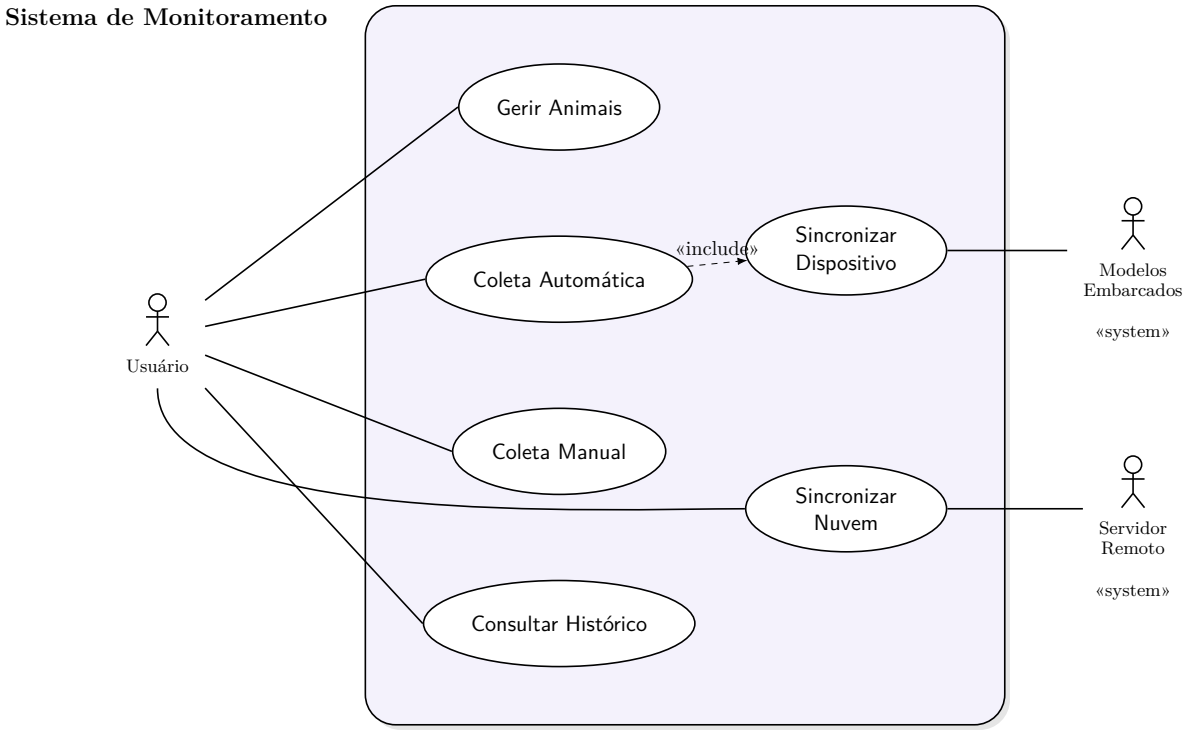


Figura 14 – Diagrama de Casos de Uso do Sistema Proposto.

Fonte: Elaborado pelo autor.

6 Resultados

Este capítulo apresenta os resultados obtidos com a avaliação do sistema desenvolvido. No intuito de contemplar todas as dimensões do trabalho, essa seção foi dividida em Testes de performance dos modelos treinados descritos na Seção 6.1, Testes de Qualidade de código, descritos na Seção 6.3 e testes de Usabilidade descritos na Seção 6.4.

6.1 Métricas de Predição de Peso

Esta seção descreve o protocolo experimental e as métricas adotadas para avaliar a etapa de predição de peso no pipeline proposto. O objetivo é quantificar o efeito da resolução de entrada, do tipo de máscara empregada (ausente, manual ou automática) e do uso de estratégias de *data augmentation* e *ensemble* sobre o desempenho dos modelos de regressão. Para assegurar comparabilidade entre experimentos, as decisões de configuração foram mantidas consistentes dentro de cada etapa do pipeline.

6.1.1 Configurações de treinamento para segmentação

Na etapa de segmentação, os modelos foram treinados sob um conjunto padronizado de hiperparâmetros, de modo a garantir uma avaliação controlada entre arquiteturas e reduzir efeitos de confusão decorrentes de ajustes específicos. A Tabela 4 resume as configurações empregadas, incluindo inicialização com pesos pré-treinados, otimização via Adam e uso da função de perda Dice, além de critérios de *early stopping* para evitar treinamento excessivo sem ganhos marginais.

Parâmetro	**Valor**
Pesos iniciais	Pré-treinados (ImageNet)
Otimizador	Adam
Função de perda	Dice
Taxa de aprendizagem	0,0003
Tamanho do lote	8
Épocas	100
Early stopping (paciência)	15 épocas

Tabela 4 – Configurações e hiperparâmetros de treinamento para segmentação.

Fonte: Elaborado pelo autor.

6.1.2 Protocolo experimental para regressão do peso

Após a etapa de segmentação, os *frames* foram utilizados como entrada para os modelos de regressão de peso. A avaliação considerou tanto a regressão direta a partir das imagens originais (isto é, sem remoção de fundo), quanto experimentos com imagens segmentadas manualmente e com imagens segmentadas automaticamente pelo modelo. Essa comparação é central do ponto de vista operacional, pois a segmentação manual funciona como referência de contorno de alta qualidade, enquanto a segmentação automática representa o cenário realista de implantação, no qual não há intervenção humana durante a execução.

Em todos os cenários, investigou-se o impacto da resolução de entrada (256, 512 e 1024 pixels). Para aumentar a robustez estatística dos resultados e reduzir viés de particionamento, adotou-se validação cruzada estratificada K-fold com $K = 5$, preservando a distribuição das amostras entre as dobras. Em paralelo, empregou-se aumento de dados (*data augmentation*) com o propósito de ampliar a capacidade de generalização e reduzir *overfitting*, especialmente relevante no contexto de coleta em propriedades rurais, onde prevalecem condições menos estruturadas e pouco controladas. Nesse tipo de ambiente, é comum haver variação de iluminação ao longo do dia, sombras projetadas, oclusões parciais, poeira e diferenças de enquadramento decorrentes do deslocamento do animal. Assim, o aumento de dados foi adotado como mecanismo prático para induzir invariâncias desejáveis e tornar o modelo mais robusto a perturbações esperadas durante a operação. Foram utilizadas transformações de espelhamento horizontal, que simulam variações de orientação e lateralidade sem alterar atributos morfológicos globais relevantes para a estimativa de peso; ajustes de brilho, que modelam flutuações típicas da iluminação natural em instalações não padronizadas; e adição de ruído Gaussiano, que aproxima degradações de captura relacionadas ao sensor, compressão e interferências ambientais, favorecendo o aprendizado de características mais estáveis e menos sensíveis a ruídos localizados.

6.1.3 Resultados com diferentes extratores de características e resoluções

A seleção dos modelos para as etapas subsequentes baseou-se nos resultados apresentados na Tabela 5. De forma geral, observou-se que a resolução de 1024×1024 produziu os melhores resultados médios em todas as métricas avaliadas, enquanto a redução para 256×256 acarretou perdas substanciais de desempenho preditivo. Em alguns casos, essa redução esteve associada a aumentos expressivos de RMSE e a quedas relevantes de R^2, evidenciando que a diminuição da resolução compromete a capacidade do modelo de capturar informações morfológicas necessárias à estimativa do peso vivo. Esse comportamento sugere que detalhes estruturais mais finos, como contorno corporal, volume aparente e proporções entre diferentes regiões anatômicas, desempenham papel importante no aprendizado regressivo. Nesse cenário, a resolução mais alta preserva melhor tais pistas

visuais, favorecendo a construção de representações mais discriminativas para a tarefa. Entre os modelos avaliados em 1024×1024, o MobileNetV2 apresentou o melhor desempenho global, com RMSE de $3{,}59 \pm 0{,}79$, MAE de $2{,}87 \pm 0{,}73$ e R^2 de $0{,}87 \pm 0{,}07$. Em paralelo, EfficientNetB1 e EfficientNetB2 também apresentaram resultados consistentes e competitivos, reforçando sua adequação para as análises comparativas subsequentes.

Resolução	**Modelo**	**RMSE**	**MAE**	$\boldsymbol{R^2}$	$\boldsymbol{r}$
1024×1024	EfficientNetB2	3.93 ± 0.64	3.03 ± 0.56	0.85 ± 0.04	0.93 ± 0.02
	DenseNet121	3.94 ± 0.71	3.17 ± 0.55	0.84 ± 0.08	0.93 ± 0.03
	EfficientNetB1	3.77 ± 0.84	$\mathbf{2.87 \pm 0.63}$	0.86 ± 0.05	$\mathbf{0.94 \pm 0.03}$
	MobileNetV2	$\mathbf{3.59 \pm 0.79}$	$\mathbf{2.87 \pm 0.73}$	$\mathbf{0.87 \pm 0.07}$	$\mathbf{0.94 \pm 0.03}$
512×512	EfficientNetB2	4.55 ± 1.12	3.35 ± 0.71	0.81 ± 0.06	0.91 ± 0.03
	DenseNet121	4.03 ± 0.99	3.13 ± 0.76	0.85 ± 0.03	0.93 ± 0.02
	EfficientNetB1	4.66 ± 1.08	3.65 ± 0.77	0.79 ± 0.09	0.91 ± 0.04
	MobileNetV2	5.41 ± 0.79	4.23 ± 0.63	0.71 ± 0.12	0.88 ± 0.03
256×256	EfficientNetB2	6.13 ± 1.06	4.61 ± 0.67	0.64 ± 0.12	0.83 ± 0.05
	DenseNet121	5.56 ± 1.53	4.31 ± 1.07	0.71 ± 0.10	0.86 ± 0.05
	EfficientNetB1	6.47 ± 1.12	4.78 ± 0.70	0.60 ± 0.11	0.82 ± 0.03
	MobileNetV2	5.06 ± 0.87	3.89 ± 0.77	0.75 ± 0.10	0.88 ± 0.06

Tabela 5 – Comparação de desempenho entre diferentes extratores de características (CNN) usando Regressão Linear. Resultados obtidos com a base segmentada manualmente.

Fonte: Elaborado pelo autor.

Com base nesses resultados, foram conduzidos experimentos adicionais com MobileNetV2, EfficientNetB1, EfficientNetB2 e DenseNet121 em 1024×1024, incluindo variações no tipo de segmentação (manual versus automática) e no uso de aumento de dados. Observou-se que o EfficientNetB2 manteve desempenho competitivo e estável, motivando sua inclusão na fase de combinação de modelos. De modo importante, a comparação entre segmentação manual e automática indicou comportamento equivalente em termos de tendência das métricas, o que reforça a viabilidade prática da abordagem automatizada.

6.1.4 Estratégias de melhora

Foram implementadas estratégias de *ensemble* com o objetivo de combinar pontos fortes complementares entre arquiteturas e mitigar limitações individuais. A Tabela 6 sintetiza os resultados. O melhor desempenho global foi observado com dados manuais, reduzindo o RMSE para $2{,}99 \pm 0{,}37$ e elevando R^2 para $0{,}92 \pm 0{,}02$, o que sugere que, quando a qualidade das máscaras é alta, a fusão de modelos tende a reduzir o erro de forma mais consistente. Em contrapartida, no cenário automatizado, o ganho do *ensemble* foi limitado, com resultados praticamente equivalentes ao melhor modelo individual, o que indica que as imperfeições inerentes à segmentação automática podem restringir os

benefícios marginais da combinação, ou ainda que o modelo individual já se encontrava próximo a um patamar de saturação para o conjunto avaliado.

Método	**RMSE**	**MAE**	$\boldsymbol{R^2}$	$\boldsymbol{r}$
Ensemble (dados automáticos)	3.43 ± 0.40	2.63 ± 0.38	0.90 ± 0.04	0.95 ± 0.02
Ensemble (dados manuais)	$\mathbf{2.99 \pm 0.37}$	$\mathbf{2.37 \pm 0.32}$	$\mathbf{0.92 \pm 0.02}$	$\mathbf{0.96 \pm 0.01}$

Tabela 6 – Resultados do método de *ensemble* para estimativa de peso.

Fonte: Elaborado pelo autor.

6.1.5 Otimização do modelo de segmentação para uso em campo

Embora os resultados de predição tenham sido satisfatórios, a etapa de segmentação pode se tornar um gargalo computacional em cenários de implantação em campo, particularmente em plataformas embarcadas. Para mitigar essa limitação, foram avaliadas estratégias de otimização e adaptação do modelo, incluindo *fine-tuning*, *transfer learning* e LoRA, visando reduzir custo de treinamento e/ou simplificar atualização do modelo sem comprometer a qualidade das máscaras.

A Tabela 7 apresenta a comparação das variantes baseadas em U-Net em termos de Dice e IoU. Observa-se que as configurações associadas ao MiT-B5 mantiveram desempenho elevado, com valores de Dice e IoU em torno de 0,97 e 0,95, respectivamente, indicando que as estratégias avaliadas preservaram a qualidade de segmentação no conjunto experimental. Complementarmente, a Tabela 8 evidencia diferenças substanciais nos custos: abordagens com *fine-tuning* pleno mantêm um grande número de parâmetros treináveis, o que tende a elevar requisitos computacionais e de armazenamento. Em contraste, a estratégia LoRA reduz significativamente os parâmetros treináveis e, sobretudo, o tamanho do *checkpoint* salvo (CKPT), mantendo métricas de acurácia comparáveis às melhores configurações. Esse resultado é particularmente relevante para ciclos de manutenção e atualização do modelo em cenários com restrição de armazenamento e conectividade, pois diminui o custo de distribuição e implantação de novas versões do segmentador, sem degradar a qualidade medida por Dice e IoU.

Modelo (U-Net)	**Dice**	**IoU (Jaccard)**
Padrão	0.94 ± 0.04	0.90 ± 0.06
EfficientNet-B7 (*fine-tuning*)	0.95 ± 0.07	0.92 ± 0.10
MiT-B5 (*fine-tuning*)	0.96 ± 0.03	0.93 ± 0.05
MiT-B5 (*transfer learning**)	0.97 ± 0.02	0.95 ± 0.04
MiT-B5 (LoRA)	0.97 ± 0.03	0.95 ± 0.04

*Em *transfer learning*, apenas a cabeça do classificador é treinada.

Tabela 7 – Resultados comparativos de desempenho das variantes de segmentação baseadas em U-Net.

Fonte: Elaborado pelo autor.

Modelo (U-Net)	**P (M)**	**PT (M)**	**TT (h)**	**EC**	**CKPT (MB)**
Padrão	34,5	34,5	5,0	45	395
Eff-B7 (FIT)	65,4	65,4	5,1	51	256
MiT-B5 (FIT)	84,7	84,7	8,6	74	323
MiT-B5 (TL*)	84,7	3,2	7,5	91	323
MiT-B5 (LoRA)	84,7	6,5	5,9	79	15

FIT: *fine-tuning*; **TL**: *transfer learning*; **P**: parâmetros totais (milhões); **PT**: parâmetros treináveis (milhões); **TT**: tempo de treinamento (horas); **EC**: época de convergência; **CKPT**: tamanho do modelo salvo (MB).
*Em *transfer learning*, apenas a cabeça do classificador é treinada.

Tabela 8 – Comparação de complexidade e custo computacional das variantes de segmentação.

Fonte: Elaborado pelo autor.

Em síntese, os resultados apontam três evidências centrais. Primeiro, a resolução de 1024×1024 mostrou-se determinante para a regressão no conjunto avaliado, elevando a consistência das estimativas ao preservar detalhes morfológicos relevantes e reduzindo a perda de informação associada à reamostragem agressiva, o que se refletiu em menores erros (RMSE/MAE) e maior explicação de variância (R^2) entre os extratores avaliados. Segundo, a comparação entre máscaras manuais e máscaras obtidas automaticamente indicou comportamento globalmente equivalente em termos de tendência das métricas, sugerindo que, no regime experimental considerado, o erro introduzido pela segmentação automática não foi suficiente para comprometer a capacidade preditiva do regressor, um resultado operacionalmente importante, pois aproxima o desempenho do cenário real de implantação (sem intervenção humana) daquele observado com contornos de referência. Terceiro, as estratégias de *ensemble* evidenciaram que a fusão de modelos é mais efetiva quando a qualidade das máscaras é alta (cenário manual), reduzindo o erro de forma mais consistente; já no cenário automatizado, o ganho marginal foi limitado, sugerindo (i) saturação do melhor modelo individual para o conjunto analisado e/ou (ii) que imperfeições residuais de contorno atuam como fonte dominante de ruído, reduzindo a complementaridade entre arquiteturas.

No que se refere à otimização do segmentador para uso em campo, as variantes baseadas em MiT-B5 mantiveram desempenho elevado (Dice/IoU próximos de 0,97/0,95), indicando que intervenções de adaptação não degradaram a qualidade das máscaras. Entretanto, do ponto de vista de implantação e manutenção, o resultado mais relevante foi a adoção de LoRA: ao reduzir drasticamente o número de parâmetros treináveis e, sobretudo, o tamanho do *checkpoint* (de centenas de MB para dezenas de MB), a estratégia preservou a acurácia de segmentação e diminuiu o custo de atualização e distribuição do modelo (armazenamento, transferência e versionamento), aspecto crítico em ambientes rurais com conectividade intermitente e restrições de infraestrutura. Assim, o conjunto de achados corrobora a viabilidade prática do *pipeline* proposto, ao combinar (i) desempenho

preditivo competitivo em alta resolução, (ii) aproximação entre segmentação automática e manual no impacto sobre a regressão e (iii) um caminho tecnicamente eficiente para atualização do segmentador em cenário de borda.

6.2 Comparação com trabalhos relacionados

A literatura recente em predição de peso de pequenos ruminantes explora desde soluções baseadas em morfometria 3D e sensores RGB-D até abordagens com extração manual de atributos e regressão, geralmente sob condições de aquisição controladas e com diferentes níveis de intervenção humana (p.ex., segmentação manual ou posicionamento restrito do animal). Conforme sintetizado na Tabela 1, os estudos reportam métricas como R^2, RMSE relativo e MAE/MAPE, variando também em tamanho amostral e instrumentação (estereovisão, Kinect, RealSense, RGB-D e RGB lateral).

Para posicionar os resultados deste trabalho em relação ao estado da arte, a Tabela 9 consolida, de forma padronizada, (i) a modalidade de aquisição, (ii) o grau de automação do pré-processamento (especialmente segmentação) e (iii) as métricas reportadas. Diferentemente de abordagens que dependem de ambientes estáticos, isolamento estrito do animal ou segmentação manual, o pipeline proposto foi concebido para operação em campo, priorizando robustez e automatização do fluxo ponta-a-ponta (captura → segmentação → regressão), em consonância com a lacuna identificada na literatura quanto à transposição de protótipos experimentais para sistemas produtivos reais.

Autor (Ano)	**Aquisição**	**Automação / Pré-processamento**	**Métrica(s)**
(MENESATTI et al., 2014)	3D (estéreo)	Aquisição controlada; extração morfométrica 3D; regressão	$R^2 = 0{,}79$
(SANT'ANA et al., 2021)	Vídeo RGB	Extração manual de atributos; RF/SVM; segmentação manual	$R^2 = 0{,}687$ (RF)
(SAMPERIO et al., 2021)	RGB-D (top-view)	Sensor RealSense; medidas/atributos; regressão linear	$R^2 = 0{,}86$
(CAMACHO-PÉREZ et al., 2022)	Profundidade (Kinect)	Modelo polinomial; seleção/ajuste via meta-heurísticas (GA/CSA)	RMSE 7,55% (CSA)
(HE et al., 2023)	RGB-D	CNN; sensível à postura/iluminação (relatado)	MAE = 6,73 kg; MAPE = 14,6%
Este trabalho	RGB lateral	Atributos visuais; CNNs	RMSE $= 3{,}43 \pm 0{,}40$; $R^2 = 0{,}90 \pm 0{,}04$

Observação: as métricas na literatura não são diretamente homogêneas (p.ex., R^2 vs. MAE/MAPE vs. RMSE relativo), portanto a comparação é apresentada de forma descritiva, destacando condições de aquisição e nível de automação.

Tabela 9 – Comparação descritiva entre trabalhos relacionados e o pipeline proposto.

Fonte: Elaborado pelo autor, com base na síntese do estado da arte.

Em termos de instrumentação, observa-se que parte dos trabalhos recorre a sensores específicos (p.ex., Kinect e RealSense) e/ou aquisição 3D/RGB-D, frequentemente associados a restrições de posicionamento e controle ambiental, bem como sensibilidade a postura e iluminação. Neste estudo, optou-se por imagens RGB laterais, reduzindo dependência de hardware especializado e favorecendo cenários de adoção em propriedades com infraestrutura limitada.

Quanto ao grau de automação, a literatura ainda apresenta dependência recorrente de etapas manuais (extração de atributos e/ou segmentação) ou requisitos de manejo que reduzem escalabilidade. Em contraste, os resultados obtidos com máscaras automáticas mostraram-se próximos aos de referência manual em termos de tendência das métricas, sustentando a viabilidade operacional do pipeline sem intervenção humana durante a execução.

Por fim, do ponto de vista de implantação e manutenção, a otimização do segmentador com LoRA preservou Dice/IoU elevados e reduziu drasticamente o tamanho do *checkpoint*, favorecendo ciclos de atualização em ambientes com restrições de armazenamento e conectividade — um aspecto pouco discutido nos trabalhos revisados, mas decisivo para a transferência tecnológica em campo.

6.3 Métricas de Qualidade de Código

Esta seção apresenta os resultados da análise estática de código aplicada aos componentes centrais do sistema: (i) o aplicativo móvel e (ii) o módulo da nuvem, chamado aqui de BFF (do inglês, *backend for front-end*). A avaliação concentrou-se em três métricas clássicas de engenharia de software — Linhas de Código (LOC), Complexidade Ciclomática (CC) e Índice de Manutenibilidade (MI) — amplamente utilizadas como indicadores indiretos de esforço de manutenção, risco de defeitos e facilidade de evolução.

Por decisão metodológica, diretórios de testes foram excluídos da análise, de modo a refletir exclusivamente o custo estrutural do código de produção.

6.3.1 Critérios de Avaliação

A Tabela 10 sintetiza os critérios utilizados para interpretação das métricas de complexidade ciclomática (CC) e índice de manutenibilidade (MI).

Os limiares de CC seguem a classificação proposta por McCabe (MCCABE, 1976), o MI baseia-se na formulação de Oman e Hagemeister (OMAN; HAGEMEISTER, 1992b), com ≥ 85 indicando alta manutenibilidade e < 65 baixa.

A métrica LOC, por sua vez, não possui um valor ideal absoluto; sua interpretação é contextual e comparativa, sendo utilizada como indicador de tamanho estrutural e

Métrica	Faixa	Interpretação
CC	1–10	Baixo risco, simples (MCCABE, 1976)
	11–20	Risco moderado
	21–50	Alto risco
	> 50	Muito alto risco, difícil de testar
MI	≥ 85	Alta manutenibilidade (OMAN; HAGEMEISTER, 1992b)
	65–84	Manutenibilidade moderada
	< 65	Baixa manutenibilidade

Tabela 10 – Critérios de referência para interpretação.

Fonte: Elaborado pelo autor

potencial esforço de manutenção.

6.3.2 Tamanho do Sistema

A Tabela 11 apresenta o volume de código analisado.

Componente	Arquivos	LOC	Linhas em branco	Comentários
Aplicação móvel	37	5098	281	53
BFF	12	283	87	21

Tabela 11 – Linhas de código (LOC) por componente (excluindo testes).

Fonte: Elaborado pelo autor.

O aplicativo móvel concentra a maior parte da base de código, o que é coerente com sua responsabilidade funcional. Já o BFF, por sua vez, apresenta dimensão reduzida, consistente com seu papel arquitetural de orquestração e adaptação entre o cliente e os serviços centrais.

Sob a perspectiva de engenharia, a manutenção tende a ser favorecida quando componentes intermediários permanecem enxutos e coesos, reduzindo a superfície de regressão e o impacto de alterações evolutivas.

6.3.3 Complexidade Ciclomática

A complexidade ciclomática (CC) quantifica o número de caminhos independentes de execução em um módulo, sendo diretamente relacionada ao esforço de teste e ao risco potencial de defeitos (MCCABE, 1976). A Tabela 12 apresenta os resultados consolidados.

Componente	Unidades analisadas	CC médio	Classificação
Aplicação móvel	12 funções	2,1	Baixa
BFF	43 blocos	1,51	Baixa

Tabela 12 – Resumo de complexidade ciclomática (CC) por componente.

Fonte: Elaborado pelo autor

Ambos os componentes apresentam CC médio inferior a 3, situando-se amplamente na faixa de baixa complexidade (1–5). Não foram identificadas unidades com CC superior a 10, limiar a partir do qual a literatura recomenda refatoração preventiva.

Esses resultados indicam que o sistema foi estruturado com funções curtas e fluxo decisório controlado, característica desejável em sistemas distribuídos com uso em campo, onde previsibilidade e facilidade de diagnóstico são requisitos operacionais críticos.

6.3.4 Índice de Manutenibilidade

O índice de manutenibilidade (MI) agrega volume, complexidade ciclomática e métricas de Halstead em uma medida sintética de facilidade de manutenção (OMAN; HAGEMEISTER, 1992b). A Tabela 13 apresenta os menores valores observados.

Arquivo	**MI**
`src/app/routers/auth.py`	58,27
`src/app/core/config.py`	71,58
`src/app/domains/sync/repository.py`	72,08

Tabela 13 – Menores índices de manutenibilidade encontrados no BFF.

Fonte: Elaborado pelo autor.

Observa-se predominância de MI máximo (100) na maioria dos arquivos, indicando alta manutenibilidade ($MI \geq 85$). Dois módulos apresentam valores na faixa moderada (65–84), enquanto apenas um arquivo situa-se ligeiramente abaixo de 65.

A redução pontual no MI ocorre em módulos de autenticação e sincronização, naturalmente mais densos em validações e tratamento de exceções. Ainda assim, tais valores não configuram criticidade estrutural, mas indicam pontos candidatos a refatorações incrementais, como extração de responsabilidades e modularização de regras de negócio.

6.3.5 Síntese dos Resultados

Com base nos critérios formais adotados, conclui-se que:

- O sistema não apresenta funções com alta complexidade ciclomática (CC $>$ 10), permanecendo integralmente na faixa de baixa complexidade.
- O MI do BFF é predominantemente classificado como alto ($\geq$ 85), com poucos módulos na faixa moderada.
- A distribuição de LOC é coerente com a arquitetura proposta, concentrando maior volume no cliente móvel e mantendo o middleware enxuto.

Sob a ótica de engenharia de software, os resultados indicam baixo risco estrutural de manutenção, previsibilidade de esforço de teste e adequação arquitetural ao cenário de uso contínuo em campo. A combinação de baixa complexidade média e alta manutenibilidade sugere que o sistema foi implementado com controle de complexidade acidental, favorecendo evolução incremental e estabilidade operacional.

6.4 Avaliação de Usabilidade

Para a avaliação de usabilidade do sistema, aplicou-se o questionário SUS a 15 participantes, estratificados em dois grupos conforme a familiaridade autorrelatada com tecnologia: (i) FT (Familiarizados com Tecnologia) e (ii) NFT (Não Familiarizados com Tecnologia). Essa estratificação foi adotada para contrastar a percepção de usabilidade sob diferentes níveis de literacia digital.

A aplicação do questionário ocorreu após a execução de um roteiro controlado de tarefas no aplicativo, cobrindo o fluxo de interface associado ao registro e consulta de informações do animal. Ressalta-se que, nesta etapa, a avaliação incidiu sobre a interação e compreensibilidade do *workflow* na interface, não contemplando ainda a utilização do sistema em um ciclo completo de coleta em campo (isto é, sob condições reais de manejo, conectividade intermitente e variabilidade ambiental), o que é coerente com a estratégia incremental de validação de um ecossistema distribuído.

O instrumento de coleta de dados baseou-se na versão em português da SUS (LOURENÇO; CARMONA; LOPES, 2022). Os itens que compõem o questionário estão detalhados na Tabela 14. Adicionalmente, a Tabela 15 sumariza a análise estatística descritiva dos escores obtidos, permitindo uma visão geral da usabilidade percebida.

A Figura 15 apresenta as pontuações SUS por participante (U01–U15), juntamente com duas referências visuais: (i) o valor de referência comumente utilizado como limiar interpretativo (SUS = 68) e (ii) a média amostral observada. Observa-se média geral de 75,7, posicionando o sistema acima do limiar de aceitabilidade e em faixa frequentemente descrita como “boa” em interpretações normativas do SUS (BANGOR; KORTUM; MILLER, 2008a; SAURO; LEWIS, 2016). Além disso, a maior parte dos participantes obteve pontuações superiores a 68, indicando consistência perceptiva positiva; entretanto, existe heterogeneidade relevante, com um subconjunto de usuários apresentando avaliações substancialmente inferiores, aspecto que orienta refinamentos de interface e treinamento.

A análise por perfil (Figura 16) evidencia uma separação marcante entre os grupos avaliados. Participantes do perfil FT apresentam distribuição deslocada para valores elevados, com concentração em patamares tipicamente associados a boa usabilidade. Em contrapartida, o perfil NFT apresenta mediana inferior e menor amplitude em torno de valores mais baixos, sugerindo barreiras de adoção associadas a diferenças de familiaridade

Item	Instrumento original em inglês	Versão usada
01	*I think that I would like to use this system frequently.*	Eu acho que gostaria de usar esse sistema frequentemente.
02	*I found the system unnecessarily complex.*	Eu achei esse sistema desnecessariamente complexo.
03	*I thought the system was easy to use.*	Eu achei esse sistema fácil de usar.
04	*I think that I would need the support of a technical person to be able to use this system.*	Eu achei que precisaria de ajuda de uma pessoa técnica para ser capaz de usar esse sistema.
05	*I found the various functions in this system were well integrated.*	Eu achei que as várias funções desse sistema foram bem integradas.
06	*I thought there was too much inconsistency in this system.*	Eu acho que o sistema apresenta muita inconsistência.
07	*I would imagine that most people would learn to use this system very quickly.*	Eu imagino que a maioria das pessoas pode aprender a usar esse sistema rapidamente.
08	*I found the system very cumbersome to use.*	Eu achei esse sistema muito pesado para usar.
09	*I felt very confident using the system.*	Eu me senti muito seguro usando o sistema.
10	*I needed to learn a lot of things before I could get going with this system.*	Eu precisei aprender muitas coisas antes que pudesse utilizar esse sistema.

Tabela 14 – Perguntas utilizadas no questionário.

Fonte: Adaptado de Lourenço, Carmona e Lopes (2022)

Perfil	Média	DP	N
FT	81,46	13,67	12
NFT	52,50	15,21	3
Geral	**75,67**	**17,54**	**15**

Tabela 15 – Estatísticas descritivas da pontuação SUS por perfil.

DP = desvio padrão; N = número de participantes.

Fonte: Elaborado pelo autor.

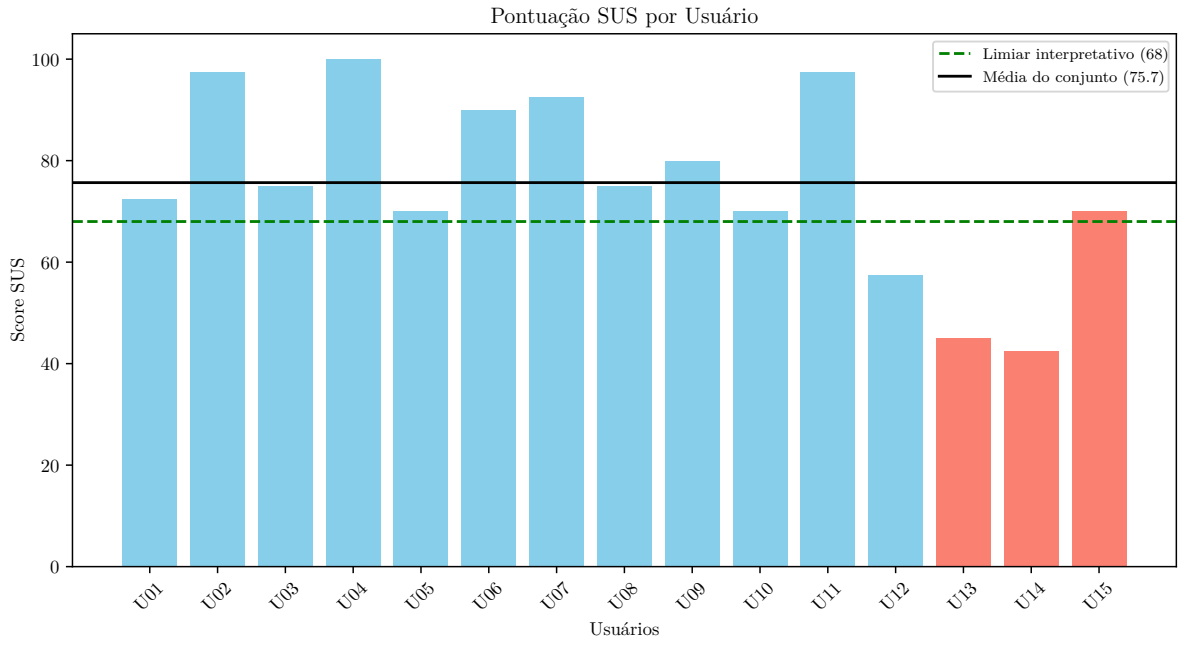


Figura 15 – Pontuação SUS por usuário, (FT marcados em azul e NFT marcados em vermelho).

Fonte: Elaborado pelo Autor.

tecnológica, vocabulário de domínio e expectativas de interação. Esse resultado é particularmente informativo: como o ecossistema foi concebido para operar em ambientes rurais com conectividade intermitente, a qualidade do *design* da interface e dos mecanismos de orientação ao usuário torna-se componente crítico para que a arquitetura *local-first* no nó de borda se traduza em efetividade operacional. Nesse sentido, os achados reforçam a necessidade de ajustes de experiência de usuário voltados ao público-alvo primário.

A relação entre idade e pontuação SUS é explorada na Figura 17. Nota-se tendência visual de escores menores em idades mais elevadas, com pontos do grupo mais velho concentrados em faixas inferiores. Todavia, esta evidência deve ser interpretada com cautela, pois o tamanho amostral é reduzido e a idade está potencialmente confundida com o perfil (isto é, participantes do perfil NFT tendem a ser mais velhos). Assim, o gráfico é útil como diagnóstico exploratório, mas não sustenta, por si só, inferências estatísticas robustas.

Em síntese, os resultados do SUS indicam que a solução, no estado atual, apresenta usabilidade global acima do limiar de referência e desempenho particularmente forte entre usuários com maior letramento digital. Ao mesmo tempo, a discrepância por perfil sinaliza que a evolução do sistema (i) deve incorporar refinamentos direcionados ao usuário rural e (ii) deve ser acompanhada por uma etapa subsequente de validação em campo, na qual a usabilidade seja observada em conjunto com as propriedades do ecossistema distribuído (operações *local-first*, sincronização eventual e controle de acesso), sob as condições reais

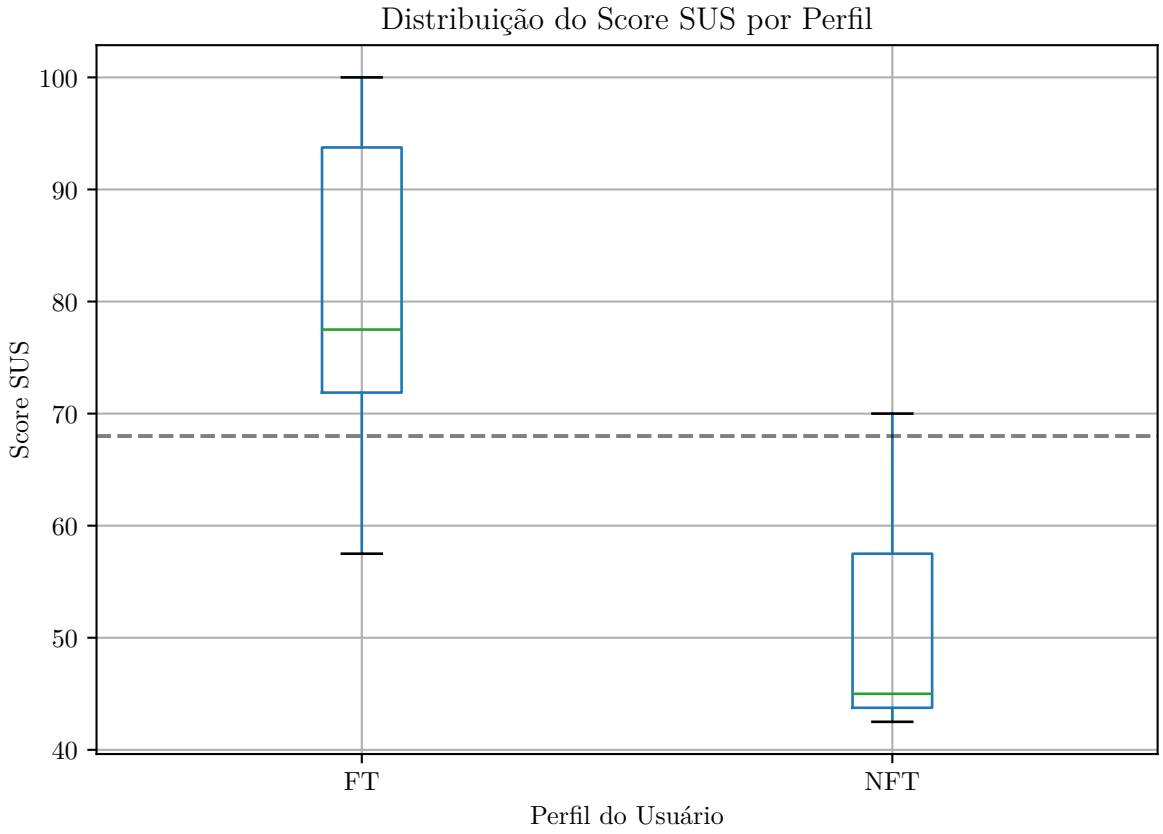


Figura 16 – Distribuição da pontuação SUS por perfil de participante.

Fonte: Elaborado pelo Autor.

para as quais a arquitetura foi projetada.

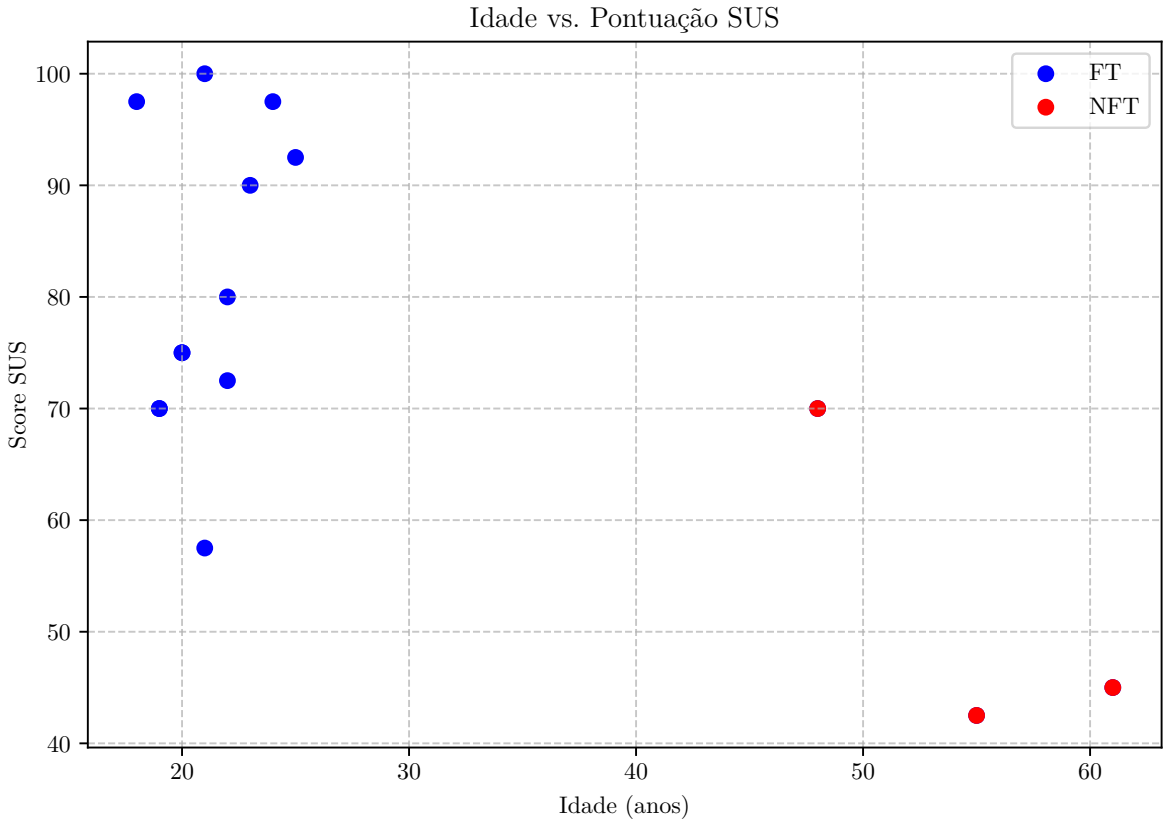


Figura 17 – Relação exploratória entre idade e pontuação SUS.

Fonte: Elaborado pelo Autor.

7 Conclusão

Esta dissertação teve como objetivo propor, implementar e avaliar um sistema para estimativa automatizada do peso de pequenos ruminantes em condições de campo, integrando visão computacional e princípios de engenharia de software adequados ao meio rural. Em vez de tratar a predição de peso como um experimento isolado de modelagem, o trabalho concentrou-se na construção de uma solução operacional completa, capaz de sustentar o ciclo de captura, inferência, registro e consulta, com ênfase em autonomia de uso em propriedades com conectividade intermitente.

A principal contribuição reside na consolidação de um fluxo ponta a ponta que aproxima a literatura de condições de uso: (i) a aquisição foi modelada para reduzir gravação contínua e custos operacionais, (ii) a segmentação foi empregada como mecanismo de controle de ruído do ambiente, e (iii) a regressão foi analisada sob variações relevantes ao contexto prático, como resolução de entrada e tipo de máscara. No conjunto experimental avaliado, observou-se que a resolução de 1024×1024 se mostrou determinante para estabilidade das estimativas, e que a segmentação automática apresentou tendência globalmente próxima à segmentação manual no impacto sobre as métricas de regressão, reforçando a viabilidade do método. Adicionalmente, a exploração de estratégias de otimização do segmentador indicou que abordagens como LoRA preservam desempenho ao mesmo tempo em que reduzem drasticamente o custo de atualização do modelo, aspecto decisivo para manutenção e evolução em cenários com restrições de infraestrutura.

No nível da aplicação, a solução foi estruturada como um MVP com funcionalidades diretamente alinhadas ao manejo: coleta automática (núcleo do sistema), coleta manual (cenários de exceção), gestão de animais e consulta a histórico com estado de sincronização. Essa modelagem reforça que o valor da estimativa automática de peso emerge quando acoplado a fluxos de trabalho concretos — registro organizado, rastreabilidade e possibilidade de análise longitudinal —, e não apenas como uma inferência pontual. Em outras palavras, o sistema foi concebido para servir como instrumento de rotina, aproximando a estimativa por visão computacional das práticas tradicionais de controle zootécnico, porém com menor intervenção humana e maior padronização do processo.

Os resultados reportados ao longo dos capítulos apoiam a viabilidade inicial da proposta em três dimensões. Primeiro, na dimensão de desempenho, observou-se sensibilidade relevante a configurações operacionais, e tendência de resultados competitivos mesmo quando se emprega segmentação automática — aspecto essencial para reduzir dependência de anotação e viabilizar uso contínuo. Segundo, na dimensão de engenharia, a análise estática indicou um sistema com estrutura previsível e baixa complexidade, o

que favorece manutenção e evolução incremental — um requisito prático para tecnologias destinadas a operação recorrente. Terceiro, na dimensão de interação, a avaliação SUS indicou usabilidade global acima do limiar de referência, embora com diferença marcante entre perfis, sinalizando que a adoção em campo depende de refinamentos de interface e de fluxos guiados para públicos com menor letramento digital.

Apesar dessas evidências, as conclusões devem ser interpretadas considerando limitações inerentes ao estágio atual do sistema. Ainda que a arquitetura tenha sido desenhada para o ambiente produtivo, falta uma validação longitudinal em propriedades rurais, sob variabilidade plena de iluminação, poeira, postura, movimento, tempo operacional e conectividade real. Do ponto de vista zootécnico, permanece necessária uma comparação extensiva e sistemática das estimativas frente a balanças comerciais em rotina de manejo, com análise por grupos (raça, idade e condição corporal) e repetição temporal por indivíduo. Além disso, embora a usabilidade tenha sido medida em tarefas controladas no aplicativo, a experiência de uso no ciclo completo em campo pode sofrer influência de fatores externos que não são capturados integralmente em laboratório.

Como trabalhos futuros, destacam-se: (i) implantação piloto em propriedades parceiras com coleta longitudinal e validação estatística contra pesagem tradicional; (ii) ampliação do conjunto de dados e sua diversificação, visando robustez e generalização; (iii) refinamento do aplicativo com foco no perfil NFT, incluindo orientação contextual, redução de carga cognitiva e ajustes de linguagem/feedback; (iv) consolidação de indicadores derivados (e.g., tendências e métricas produtivas) a partir do histórico, reforçando o papel do sistema como ferramenta de monitoramento contínuo; e (v) aprofundamento das estratégias de atualização eficiente dos modelos e do mecanismo de sincronização eventual, assegurando ciclos sustentáveis de manutenção em cenários com restrições de conectividade e armazenamento.

Em síntese, a dissertação contribui ao entregar um sistema para estimativa de peso e registro zootécnico em condições de campo, no qual a visão computacional é integrada a fluxos de uso compatíveis com a realidade operacional da ovinocaprinocultura. Ao priorizar a solução completa, este trabalho oferece uma base arquitetural e metodológica para pesquisas futuras que busquem consolidar a transferência tecnológica da estimativa por visão computacional do ambiente experimental para a rotina produtiva.

Referências

APHEX34. *Convolutional Neural Network*. 2015. Acessado em: 29 jan. 2026. Disponível sob licença CC BY-SA 4.0. Disponível em: <https://commons.wikimedia.org/wiki/File:Convolutional_Neural_Network.png>. Citado na página 6.

BANGOR, A.; KORTUM, P.; MILLER, J. An empirical evaluation of the system usability scale. *International Journal of Human-Computer Interaction*, v. 24, n. 6, p. 574–594, 2008. Citado na página 42.

BANGOR, A.; KORTUM, P. T.; MILLER, J. T. An empirical evaluation of the system usability scale. *Intl. Journal of Human–Computer Interaction*, Taylor & Francis, v. 24, n. 6, p. 574–594, 2008. Citado na página 16.

BROOKE, J. et al. Sus-a quick and dirty usability scale. *Usability evaluation in industry*, London, England, v. 189, n. 194, p. 4–7, 1996. Citado na página 16.

CAMACHO-PÉREZ, E. et al. Towards the estimation of body weight in sheep using metaheuristic algorithms from biometric parameters in microsystems. *Micromachines*, MDPI, v. 13, n. 8, p. 1325, 2022. Citado 4 vezes nas páginas 10, 19, 20 e 38.

CARVALHO, F. d. et al. Ganho em peso médio diário de diferentes grupos genéticos de bovinos de corte. *Pubvet*, v. 11, n. 1, p. 87–90, 2 2017. Disponível em: <https://ojs.pubvet.com.br/index.php/revista/article/view/1392>. Citado na página 1.

CHAI, T.; DRAXLER, R. R. Root mean square error (rmse) or mean absolute error (mae)?–arguments against avoiding rmse in the literature. *Geoscientific model development*, v. 7, n. 3, p. 1247–1250, 2014. Citado na página 12.

CHEUNG, L. *Weighing cattle - Wasco County Fair 2014*. [S.l.]: Wikimedia Commons / USDA, 2014. Disponível em: <https://commons.wikimedia.org/wiki/File:Weighing_cattle_-_Wasco_County_Fair_2014.jpg>. Acesso em: 24 maio 2024. Citado na página 11.

CHICCO, D.; WARRENS, M. J.; JURMAN, G. The coefficient of determination r-squared is more informative than smape, mae, mape, mse and rmse in regression analysis evaluation. *PeerJ Computer Science*, PeerJ Inc., v. 7, p. e623, 2021. Citado na página 12.

CHOLLET, F. Xception: Deep learning with depthwise separable convolutions. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2017. p. 1251–1258. Citado na página 26.

DALAL, N.; TRIGGS, B. Histograms of oriented gradients for human detection. In: IEEE. *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05)*. [S.l.], 2005. v. 1, p. 886–893. Citado na página 5.

DENG, J. et al. Imagenet: A large-scale hierarchical image database. In: IEEE. *2009 IEEE conference on computer vision and pattern recognition*. [S.l.], 2009. p. 248–255. Citado na página 9.

EELBODE, T. et al. Optimization for medical image segmentation: theory and practice when evaluating with dice score or jaccard index. *IEEE transactions on medical imaging*, IEEE, v. 39, n. 11, p. 3679–3690, 2020. Citado na página 9.

EMBRAPA. *Ciência abre novas oportunidades na produção de caprinos e ovinos*. 2023. Accessed: 2025-01-17. Disponível em: <https://www.embrapa.br/busca-de-noticias/>. Citado na página 1.

EMBRAPA. *Embrapa discute abertura de mercado para exportação de ovinos em missão no Kuwait*. 2025. Disponível em: <https://www.embrapa.br/busca-de-noticias/-/noticia/98055449/embrapa-discute-abertura-de-mercado-para-exportacao-de-ovinos-em-missao-no-kuwait>. Acesso em: 16 Ago. 2025. Citado na página 1.

GEBREYESUS, G. et al. Supervised learning techniques for dairy cattle body weight prediction from 3d digital images. *Frontiers in Genetics*, v. 13, p. 947176, Jan 2023. Disponível em: <https://doi.org/10.3389/fgene.2022.947176>. Citado na página 11.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. Disponível em: http://www.deeplearningbook.org. Citado 3 vezes nas páginas 5, 6 e 10.

HAMADANI, A.; GANAI, N. A. Artificial intelligence algorithm comparison and ranking for weight prediction in sheep. *Scientific Reports*, v. 13, n. 1, p. 13242, Aug 2023. Disponível em: <https://doi.org/10.1038/s41598-023-40528-4>. Citado na página 10.

HE, C. et al. Enhanced litehrnet based sheep weight estimation using rgb-d images. *Computers and Electronics in Agriculture*, Elsevier, v. 206, p. 107667, 2023. Citado 3 vezes nas páginas 19, 20 e 38.

HE, K. et al. Mask r-cnn. In: *Proceedings of the IEEE international conference on computer vision*. [S.l.: s.n.], 2017. p. 2961–2969. Citado na página 8.

HE, K. et al. Deep residual learning for image recognition. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2016. p. 770–778. Citado na página 26.

HOWARD, A. G. et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications. In: . [S.l.: s.n.], 2017. Citado na página 26.

HUANG, G. et al. Densely connected convolutional networks. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2017. p. 4700–4708. Citado 2 vezes nas páginas 9 e 26.

HUANG, G. et al. *Densely Connected Convolutional Networks*. 2018. Disponível em: <https://arxiv.org/abs/1608.06993>. Citado na página 26.

IBGE. *Contas Nacionais Trimestrais – Indicadores de Volume e Valores Correntes*. 2025. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/contas-nacionais/9300-contas-nacionais-trimestrais.html>. Acesso em: 16 Ago. 2025. Citado na página 1.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. *Ergonomics of human-system interaction – Part 11: Usability: Definitions and concepts*. Geneva, Switzerland, 2018. Citado na página 16.

JOCHER, G.; QIU, J.; CHAURASIA, A. *Ultralytics YOLO*. 2023. Disponível em: <https://github.com/ultralytics/ultralytics>. Citado na página 24.

KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014. Citado na página 10.

KLEPPMANN, M. et al. *Local-First Software: You Own Your Data, in spite of the Cloud*. 2019. Paper seminal definindo princípios local-first: prioriza armazenamento/uso local, opera offline em áreas rurais com conectividade patchy, sync complementar. Aplicável a apps de campo. Acessado em 30 jan. 2026. Disponível em: <https://martin.kleppmann.com/papers/local-first.pdf>. Citado na página 15.

KOHAVI, R. et al. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: MONTREAL, CANADA. *Ijcai*. [S.l.], 1995. v. 14, n. 2, p. 1137–1145. Citado na página 10.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015. Citado 2 vezes nas páginas 5 e 9.

LEE, J.; KIM, D.; LEE, J. Efficient object detection using semantic region of interest generation from 3d lidar data. *Applied Sciences*, MDPI, v. 13, n. 22, p. 12159, 2023. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC10647654/>. Citado na página 7.

LIN, T.-Y. et al. Feature pyramid networks for object detection. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2017. p. 2117–2125. Citado na página 26.

LONG, J.; SHELHAMER, E.; DARRELL, T. Fully convolutional networks for semantic segmentation. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2015. p. 3431–3440. Citado na página 7.

LOURENÇO, D. F.; CARMONA, E. V.; LOPES, M. H. B. de M. Tradução e adaptação transcultural da system usability scale para o português do brasil. *Aquichan*, Facultad de Enfermería, v. 22, n. 2, p. 8, 2022. Citado 2 vezes nas páginas 42 e 43.

LOWE, D. G. Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, Springer, v. 60, n. 2, p. 91–110, 2004. Citado na página 5.

MALLICK, S. *Moving Object Detection with OpenCV*. 2015. <https://learnopencv.com/moving-object-detection-with-opencv/>. Acessado em: 12 fev. 2026. Citado na página 24.

MAPA, M. da Agricultura e P. Acesso à internet é desafio para ampliar a agricultura de precisão. 2025. Acessado em 30 jan. 2026. Disponível em: <https://www.gov.br/agricultura/pt-br/assuntos/noticias/2022/acesso-a-internet-e-desafio-para-ampliar-a-agricultura-de-precisao>. Citado na página 13.

MARQUES, J. V. M. et al. Detection of covid-19 in computed tomography images using deep learning. In: ABRAHAM, A. et al. (Ed.). *Intelligent Systems Design and Applications*. Cham: Springer Nature Switzerland, 2023. p. 143–152. ISBN 978-3-031-35510-3. Citado na página 8.

MCCABE, T. J. A complexity measure. *IEEE Transactions on software Engineering*, IEEE, n. 4, p. 308–320, 1976. Citado 3 vezes nas páginas 17, 39 e 40.

MENESATTI, P. et al. A low-cost stereovision system to estimate size and weight of live sheep. *Computers and Electronics in Agriculture*, Elsevier, v. 103, p. 33–38, 2014. Citado 2 vezes nas páginas 19 e 38.

MORGAN-DAVIES, C. et al. Review: Exploring the use of precision livestock farming for small ruminant welfare management. *animal*, v. 18, p. 101233, 2024. ISSN 1751-7311. Selected keynote lectures of the 74th Annual Meeting of the European Federation of Animal Science (Lyon, France). Disponível em: <https://www.sciencedirect.com/science/article/pii/S1751731124001642>. Citado na página 1.

NORMAN, D. L.; BISCHOFF, P. H.; WEARN, O. R. Can cnn-based species classification generalise across variation in habitat within a camera trap survey? *Methods in Ecology and Evolution*, British Ecological Society, v. 13, n. 2, p. 242–254, 2022. Disponível em: <https://besjournals.onlinelibrary.wiley.com/doi/abs/10.1111/2041-210X.14031>. Citado na página 6.

OBJECT MANAGEMENT GROUP. *OMG Unified Modeling Language (OMG UML)*. Version 2.5.1. [S.l.], 2017. Acessado em: 01 fev. 2026. Disponível em: <https://www.omg.org/spec/UML/>. Citado na página 30.

OMAN, P.; HAGEMEISTER, J. Metrics for assessing a software system's maintainability. In: IEEE. *Proceedings Conference on Software Maintenance 1992*. [S.l.], 1992. p. 337–344. Citado na página 17.

OMAN, P.; HAGEMEISTER, J. Metrics for assessing a software system's maintainability. *Proceedings Conference on Software Maintenance 1992*, p. 302–310, 1992. Citado 3 vezes nas páginas 39, 40 e 41.

PAN, S. J.; YANG, Q. A survey on transfer learning. *IEEE Transactions on knowledge and data engineering*, IEEE, v. 22, n. 10, p. 1345–1359, 2009. Citado na página 9.

QIAO, K. et al. Effective and efficient roi-wise visual encoding using an end-to-end cnn regression model and selective optimization. *arXiv preprint arXiv:1907.11885*, 2019. Disponível em: <https://arxiv.org/abs/1907.11885>. Citado na página 6.

RABELLO, A.; BRAGA, P. H. A.; SCHULTZ, E. B. Tecnologias aplicadas ao monitoramento de parâmetros fisiológicos na produção de ruminantes. *Revista Agrária Acadêmica*, v. 6, n. 2, p. 27–37, 2023. Citado na página 1.

RONNEBERGER, O.; FISCHER, P.; BROX, T. *U-Net: Convolutional Networks for Biomedical Image Segmentation*. 2015. Disponível em: <https://arxiv.org/abs/1505.04597>. Citado 3 vezes nas páginas 7, 8 e 26.

SAMPERIO, E. et al. Lambs' live weight estimation using 3d images. *Animal*, Elsevier, v. 15, n. 5, p. 100212, 2021. Citado 2 vezes nas páginas 19 e 38.

SANDLER, M. et al. Mobilenetv2: Inverted residuals and linear bottlenecks. In: *CVPR*. [S.l.: s.n.], 2018. p. 4510–4520. Citado na página 26.

SANT'ANA, D. A. et al. Weighing live sheep using computer vision techniques and regression machine learning. *Machine Learning with Applications*, Elsevier, v. 5, p. 100076, 2021. Citado 2 vezes nas páginas 19 e 38.

SAURO, J. A practical guide to the system usability scale: Background, benchmarks, and best practices. *Denver, CO: Measuring Usability LLC*, 2011. Citado na página 16.

SAURO, J.; LEWIS, J. R. *Quantifying the User Experience: Practical Statistics for User Research*. 2. ed. [S.l.]: Morgan Kaufmann, 2016. Citado na página 42.

SHI, R.; NGAN, K. N.; LI, S. Jaccard index compensation for object segmentation evaluation. In: IEEE. *2014 IEEE international conference on image processing (ICIP)*. [S.l.], 2014. p. 4457–4461. Citado na página 9.

SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on image data augmentation for deep learning. *Journal of big data*, Springer, v. 6, n. 1, p. 1–48, 2019. Citado na página 10.

SILVA, B. Agricultura digital: desafio da conectividade no campo para a agricultura familiar. *Mirante*, 2024. Discute barreiras de conectividade precária na agricultura familiar brasileira, com falta de infraestrutura e cobertura rural. Acessado em 30 jan. 2026. Disponível em: <https://www.revista.ueg.br/index.php/mirante/article/view/16190>. Citado 2 vezes nas páginas 1 e 15.

SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. In: *International Conference on Learning Representations (ICLR)*. [S.l.: s.n.], 2015. Citado na página 26.

SZEGEDY, C. et al. Inception-v4, inception-resnet and the impact of residual connections on learning. In: *AAAI Conference on Artificial Intelligence*. [S.l.: s.n.], 2017. Citado na página 26.

SZEGEDY, C. et al. Rethinking the inception architecture for computer vision. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2016. p. 2818–2826. Citado na página 26.

SZELISKI, R. *Computer Vision: Algorithms and Applications*. 2nd. ed. Cham: Springer, 2022. (Texts in Computer Science). Citado na página 5.

TAN, M.; LE, Q. Efficientnet: Rethinking model scaling for convolutional neural networks. In: *Proceedings of the 36th International Conference on Machine Learning (ICML)*. [S.l.: s.n.], 2019. p. 6105–6114. Citado na página 26.

Walsh Medical Media. Precision agriculture for smallholder farmers: Challenges and opportunities. *Journal of Agriculture and Environmental Sciences*, v. 12, n. 3, p. 1–10, 2023. Enfatiza conectividade e infraestrutura como barreiras para smallholders. Acessado em 30 jan. 2026. Disponível em: <https://www.walshmedicalmedia.com/open-access/precision-agriculture-for-smallholder-farmers-challenges-and-opportunities.pdf>. Citado 2 vezes nas páginas 1 e 13.

WANG, e. a. Ai-powered cow detection in complex farm environments. *arXiv preprint arXiv:2501.02080*, 2024. Disponível em: <https://arxiv.org/html/2501.02080v1>. Citado na página 7.

WANG, J. et al. Predicting weight of goats using 3d imaging and machine learning techniques. *Computers and Electronics in Agriculture*, 2021. Citado 2 vezes nas páginas 10 e 11.

WANG, S.; VELDHUIS, R.; STRISCIUGLIO, N. The robustness of computer vision models against common corruptions: a survey. *arXiv preprint arXiv:2305.06024*, v. 2, n. 4, 2023. Citado na página 5.

WELKER, K. D. The software maintainability index revisited. *Crosstalk*, v. 14, n. 8, p. 18–21, 2001. Citado na página 17.

WILLMOTT, C. J.; MATSUURA, K. Advantages of the mean absolute error (mae) over the root mean square error (rmse) in assessing average model performance. *Climate research*, v. 30, n. 1, p. 79–82, 2005. Citado na página 12.

XIE, E. et al. Segformer: Simple and efficient design for semantic segmentation with transformers. In: *Advances in Neural Information Processing Systems (NeurIPS)*. [S.l.: s.n.], 2021. Citado na página 26.

YOSINSKI, J. et al. How transferable are features in deep neural networks? In: *Advances in neural information processing systems*. [S.l.: s.n.], 2014. v. 27. Citado na página 9.

ZHOU, Z. et al. Unet++: Redesigning skip connections to exploit multiscale features in image segmentation. *IEEE Transactions on Medical Imaging*, 2019. Citado na página 26.

Apêndices

APÊNDICE A – Interfaces do Aplicativo Móvel

Este apêndice apresenta o design de interface do aplicativo móvel desenvolvido como parte da arquitetura da solução proposta nesta dissertação.

A Figura 18 ilustra a tela inicial do aplicativo. O *dashboard* principal foi estruturado para fornecer acesso rápido às funcionalidades centrais do sistema. Destaca-se visualmente a opção de "Coleta Automática", módulo responsável por interfacear com o dispositivo embarcado e processar as estimativas de peso via algoritmos de visão computacional, em contraste com a "Coleta Manual"e a gestão tradicional.

A.1 Módulo de Gestão

Para a administração do rebanho, o sistema implementa uma interface de listagem (Figura 19), que sumariza as informações críticas de cada animal, como identificação (brinco), raça e a última medição de peso registrada.

Considerando a realidade operacional da agricultura familiar e de propriedades de diferentes portes, a ferramenta incorpora mecanismos de filtragem contextual. As Figuras 20 e 21 demonstram, respectivamente, os modais de seleção por "Propriedade"e por "Lote". Essa divisão reflete o manejo zootécnico prático, permitindo que o produtor organize os dados de forma aderente à topologia da sua fazenda.

Por fim, ao selecionar um indivíduo específico, o usuário acessa a tela de Perfil do Animal (Figura 22). Além dos metadados biológicos estáticos, a interface apresenta o histórico cronológico de aferições de peso e Escore de Condição Corporal (ECC). Do ponto de vista da transparência algorítmica e da confiança do usuário no sistema, a interface utiliza recursos visuais e textuais para diferenciar explicitamente os dados gerados pelo modelo de visão computacional (indicados com o selo "Automática/Sistema") das anotações inseridas pelo tratador ("Manual"). Essa rastreabilidade é fundamental para a avaliação contínua da precisão do sistema em condições reais de campo.

A.2 Módulo de Coleta Manual e Fenotipagem

O módulo de Coleta Manual foi desenvolvido para garantir a resiliência operacional do sistema e permitir o registro de dados biométricos detalhados que extrapolam a estimativa de peso isolada. A interface foi concebida considerando o contexto operacional do

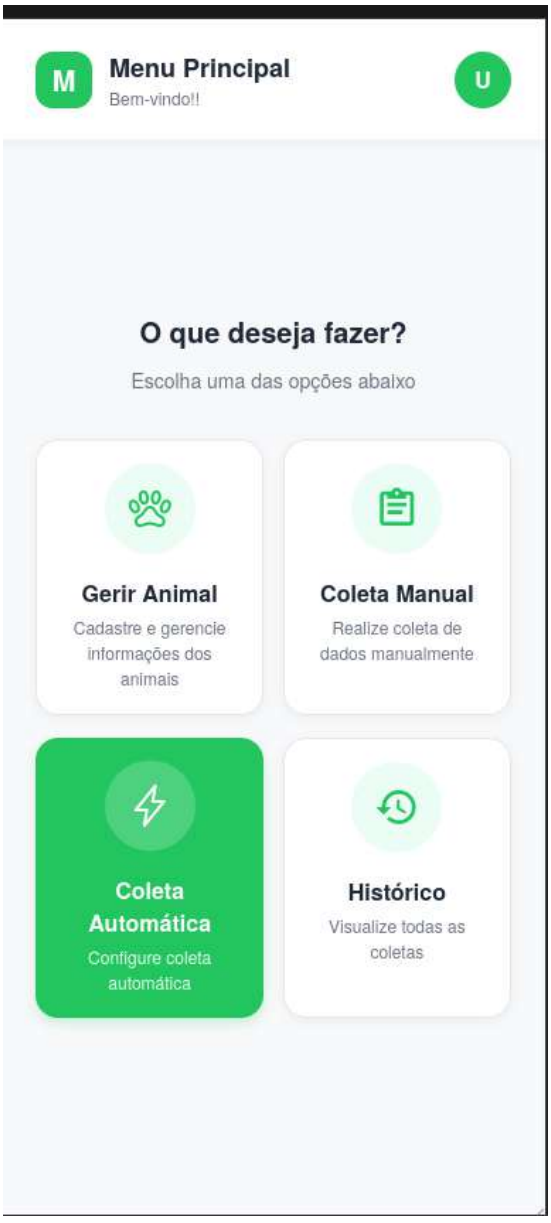


Figura 18 – Tela inicial do aplicativo móvel (Menu Principal), destacando as opções de gestão e os métodos de coleta de dados de peso, com ênfase na coleta automática.

Fonte: Elaborado pelo autor.



Figura 19 – Tela de listagem do rebanho, apresentando cartões individuais com resumo de identificação, raça e a última medição de peso registrada para o animal.

Fonte: Autoria própria.



Figura 20 – Modal de seleção de propriedades rurais, permitindo ao produtor filtrar a listagem de animais de acordo com a fazenda de origem.

Fonte: Autoria própria.

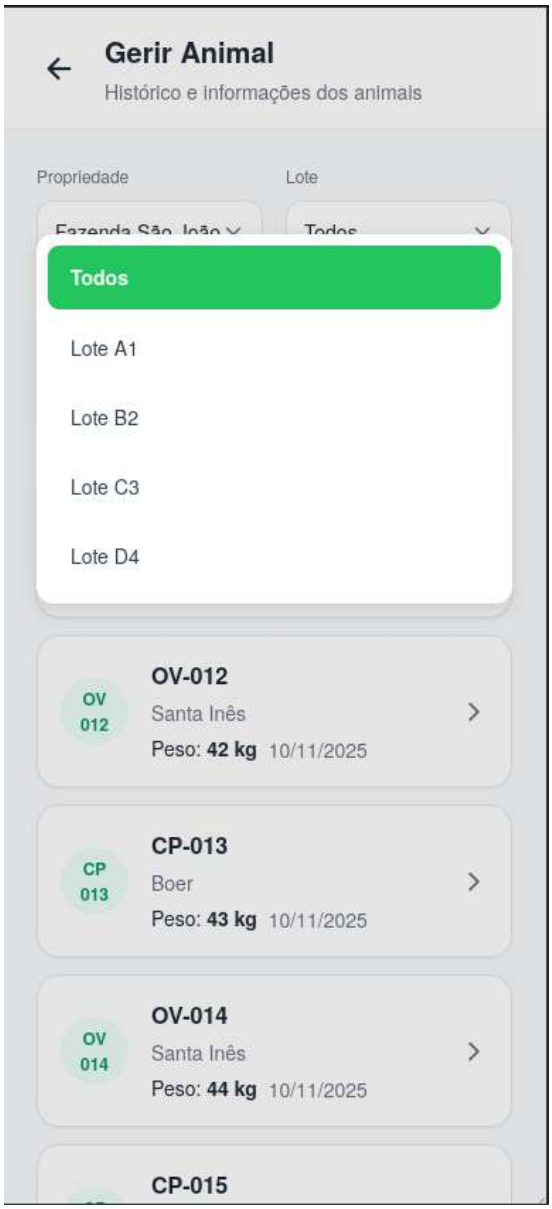


Figura 21 – Modal de seleção de lotes, refletindo a organização prática do manejo zootécnico e facilitando a busca em grandes rebanhos.

Fonte: Autoria própria.



Figura 22 – Perfil individual do animal apresentando dados cadastrais e o histórico de pesagens. Destaca-se a diferenciação visual e textual entre coletas de dados automáticas (via visão computacional) e manuais.

Fonte: Autoria própria.

manejo em curral, caracterizado por ambiente dinâmico, iluminação variável e necessidade de interação rápida. Dado que o público-alvo inclui operadores rurais com diferentes níveis de letramento digital, o fluxo foi estruturado em três etapas lógicas e sequenciais — configuração da sessão, identificação do animal e registro das variáveis morfométricas — com o objetivo de reduzir carga cognitiva, minimizar o número de interações na tela e otimizar o tempo total de operação. A organização hierárquica das ações buscou favorecer usabilidade em condições reais de campo, nas quais o operador executa múltiplas tarefas simultaneamente e dispõe de tempo limitado para manipulação do dispositivo móvel. Tal abordagem está alinhada aos princípios de design centrado no usuário aplicados à Agricultura 4.0, priorizando simplicidade, previsibilidade e eficiência operacional.

A Figura 23 apresenta o menu inicial do módulo, oferecendo o início de uma nova sessão ou a consulta ao histórico de coletas manuais prévias. Ao iniciar uma nova coleta, o usuário deve preencher os metadados da sessão (Figura 24), estabelecendo o contexto ambiental e de manejo (data, período, responsável e localização espacial do rebanho). Essa abordagem de configuração em lote evita a entrada redundante de dados para cada animal avaliado no mesmo manejo.

Com o contexto definido, o aplicativo exibe a listagem de animais correspondentes ao lote selecionado (Figuras 25 e 26). A interface fornece *feedback* visual imediato (indicador verde "Selecionado") para facilitar o controle de quais indivíduos já foram processados na sessão atual, reduzindo a carga cognitiva do operador.

A etapa de inserção de dados zootécnicos é o núcleo deste módulo. Para acomodar um grande volume de variáveis sem sobrecarregar a interface, o formulário foi fragmentado em categorias navegáveis por meio de abas superiores. A Figura 27 ilustra a aba principal de "Medição", focada no registro do peso vivo e do Escore de Condição Corporal (ECC). A Figura 28 apresenta a aba "CPM", dedicada à avaliação visual de Conformação, Precocidade e Musculatura, características essenciais em rebanhos de corte.

As abas subsequentes habilitam uma fenotipagem intensiva do animal, cobrindo dimensões fundamentais para estudos de melhoramento genético e validação de modelos de visão computacional. As interfaces coletam dados lineares de Altura (Figura 29), Comprimento (Figura 30), Perímetros (Figura 31) e Largura (Figura 32).

Para complementar o fluxo operacional e garantir a rastreabilidade dos manejos, o módulo dispõe de uma interface de "Histórico Manual"(Figura 33). Esta tela lista as sessões previamente realizadas, apresentando metadados consolidados como data, propriedade, lote e o número de animais avaliados. Destaca-se nesta interface a materialização visual da arquitetura *Local-First* proposta nesta dissertação: cada registro possui um *badge* (etiqueta) de status de sincronização, indicando se os dados estão persistidos apenas no armazenamento interno do dispositivo móvel ("LOCAL") ou se já foram transmitidos com sucesso para a base de dados em nuvem ("ENVIADO"). Esse mecanismo assegura



Figura 23 – Menu do módulo de Coleta Manual, com opções para iniciar um novo manejo ou acessar o histórico local.

Fonte: Autoria própria.

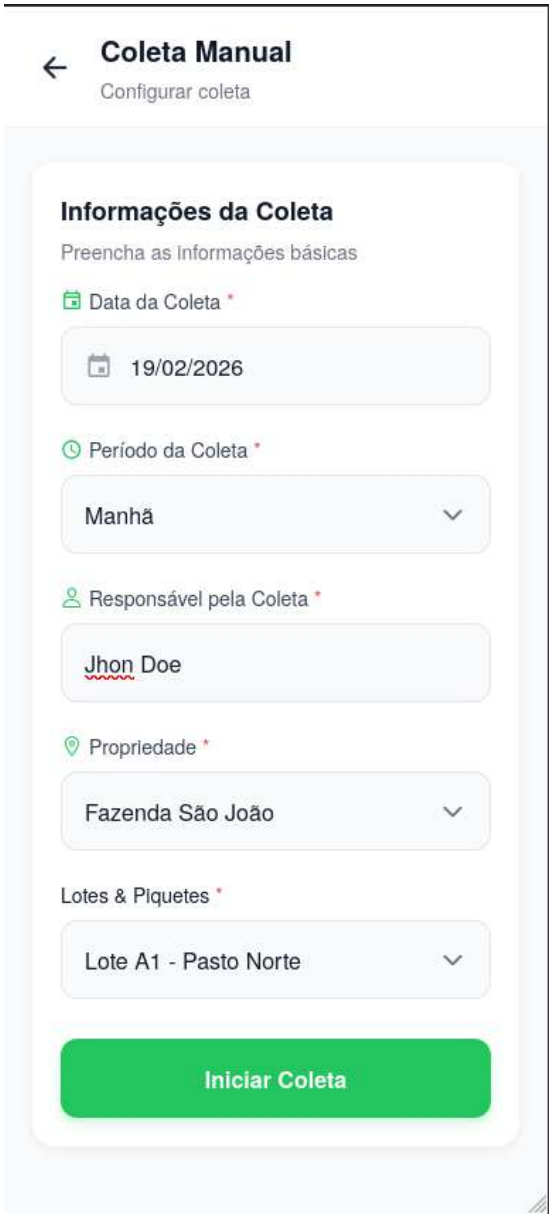


Figura 24 – Tela de configuração da sessão de coleta, registrando metadados de manejo como data, período, responsável, propriedade e lote.

Fonte: Autoria própria.



Figura 25 – Interface de seleção de animais dentro do lote configurado para a sessão de coleta.

Fonte: Autoria própria.



Figura 26 – Detalhe do *feedback* visual indicando a seleção bem-sucedida de um animal para o registro de dados.

Fonte: Autoria própria.



Figura 27 – Aba principal de registro zootécnico, contendo campos para inserção manual do peso (kg) e do Escore de Condição Corporal (ECC).

Fonte: Autoria própria.

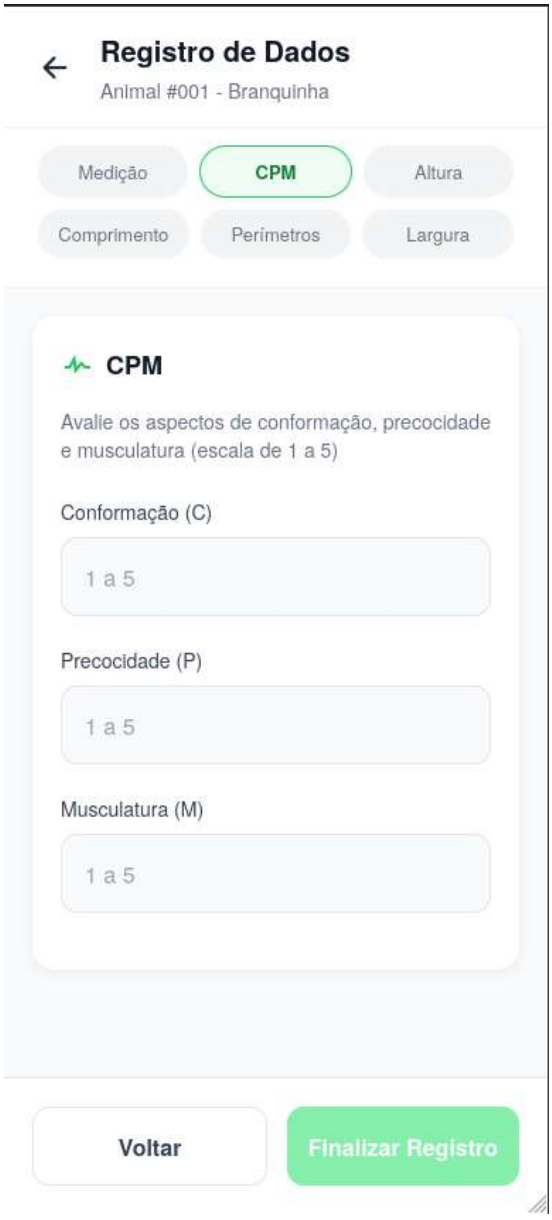


Figura 28 – Aba de avaliação CPM, permitindo o registro de escores de Conformação, Precocidade e Musculatura.

Fonte: Autoria própria.



Figura 29 – Formulário de coleta de medidas verticais, incluindo altura da garupa, cernelha e perna.

Fonte: Autoria própria.



Figura 30 – Aba dedicada às medidas horizontais e longitudinais do animal.

Fonte: Autoria própria.

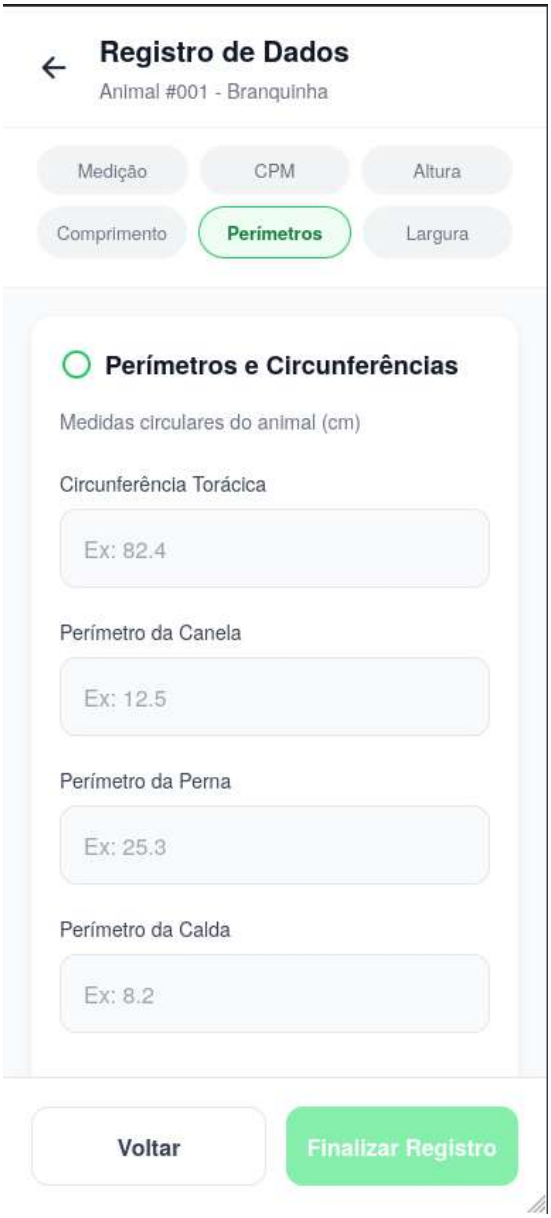


Figura 31 – Interface para inserção de perímetros e circunferências corporais, com destaque para a circunferência torácica, frequentemente correlacionada com o peso vivo.

Fonte: Autoria própria.

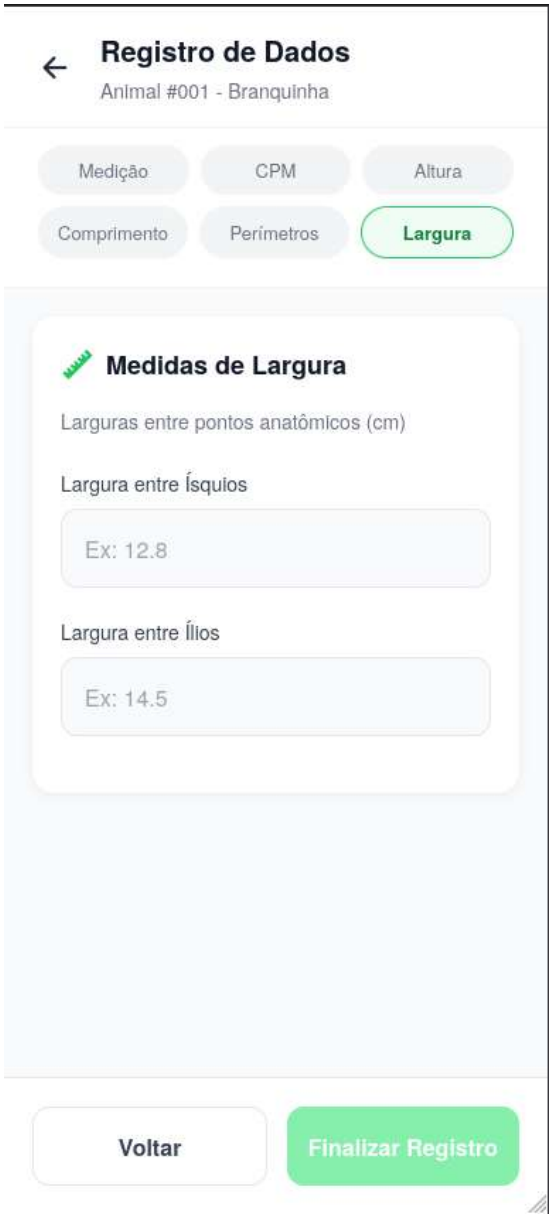


Figura 32 – Formulário para registro de larguras entre pontos anatômicos específicos (ísquios e ílios).

Fonte: Autoria própria.

transparência ao produtor e mitigação de perda de dados zootécnicos em cenários de intermitência ou ausência de conectividade de rede no meio rural.

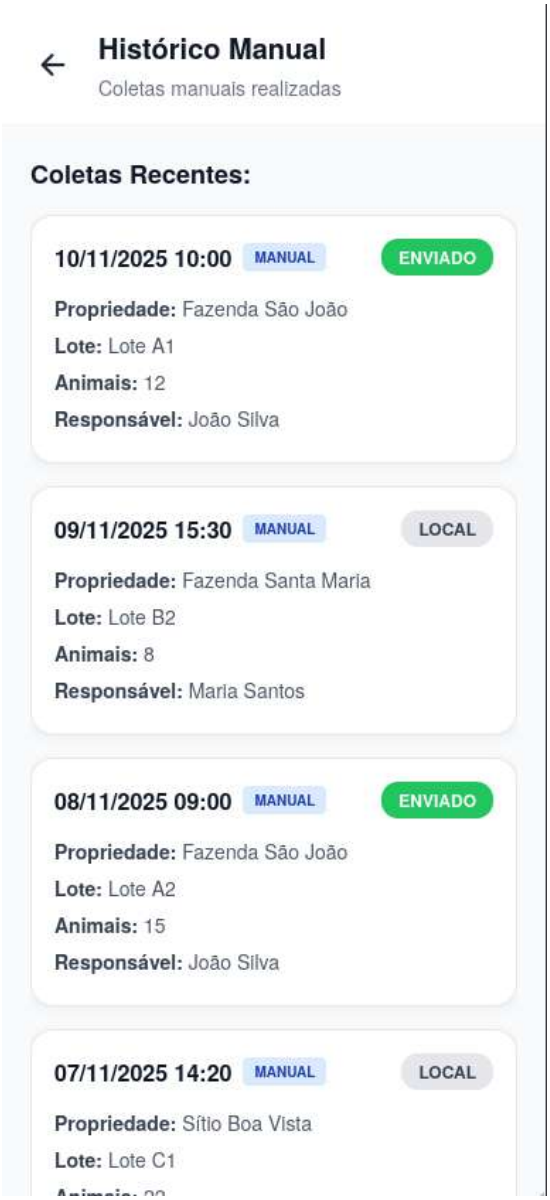


Figura 33 – Interface de histórico de coletas manuais, evidenciando o status de sincronização dos pacotes de dados (*Local* vs. *Enviado*), característica fundamental da arquitetura *Local-First*.

Fonte: Autoria própria.

A.3 Módulo de Coleta Automática e Integração na Borda

O módulo de Coleta Automática constitui a camada operacional da solução desenvolvida, responsável por integrar o processo de inferência baseado em visão computacional ao contexto prático de uso em campo.

O acesso a esse módulo ocorre por meio do menu principal do sistema, conforme ilustrado na Figura 34. A interface foi estruturada com base em princípios de hierarquia visual e redução de carga cognitiva, priorizando a funcionalidade principal de captura automática por meio do destaque visual dado ao componente interativo correspondente. Ao ingressar no módulo, o usuário é direcionado ao menu de operação automática, apresentado na Figura 35.

Nessa interface, a funcionalidade *Iniciar Captura* explicita a necessidade de sincronização entre o aplicativo móvel e o hardware embarcado. Essa etapa é fundamental para a arquitetura distribuída proposta, pois estabelece a comunicação em rede local (LAN), sem dependência de conectividade com a internet. Dessa forma, torna-se possível receber os dados de peso estimados pelo modelo híbrido, composto por extrator convolucional de características e regressão linear, mesmo em ambientes com conectividade limitada. Adicionalmente, o módulo permite o acesso direto ao histórico de capturas automatizadas realizadas anteriormente.

Antes de iniciar o ciclo de capturas de imagem e inferências de peso de um lote de animais, o sistema requer a parametrização da sessão de manejo. A Figura 36 ilustra o formulário de Configuração da Coleta. A exigência estruturada de dados como data, propriedade e lote assegura que cada inferência seja associada a identificadores consistentes, permitindo a integridade referencial no banco de dados local.

Do ponto de vista operacional, o módulo foi concebido para minimizar o tempo de contenção individual e reduzir o estresse animal quando comparado à pesagem convencional em balança, contribuindo para maior eficiência do manejo em propriedades rurais.

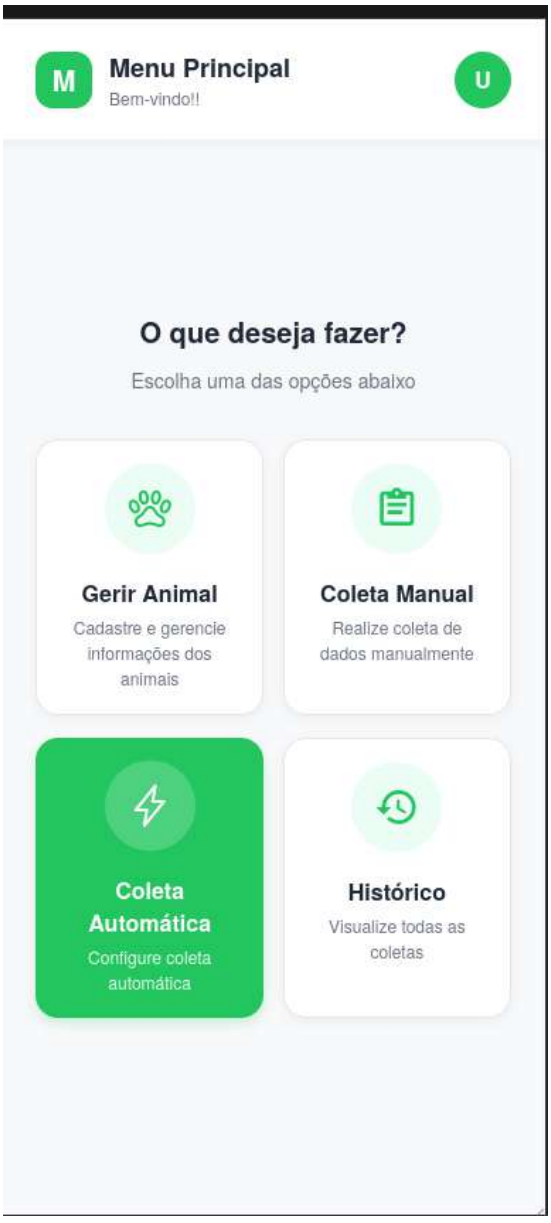


Figura 34 – Interface principal do sistema, evidenciando o acesso ao módulo de Coleta Automática, elemento central para a operação do sistema de pesagem por visão computacional.

Fonte: Autoria própria.

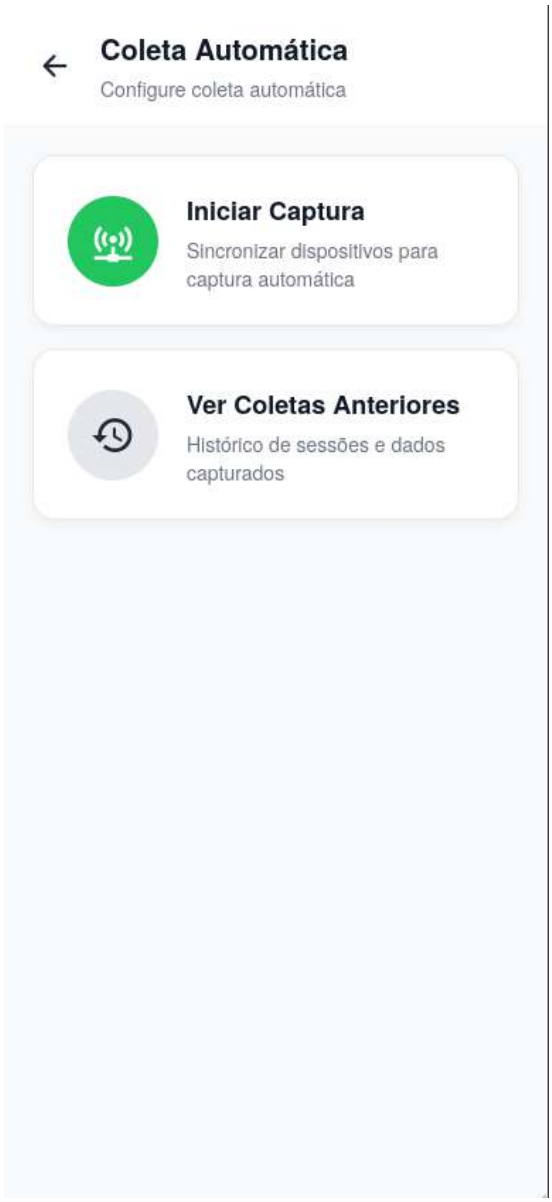


Figura 35 – Menu do módulo de Coleta Automática, destacando a rotina de sincronização entre o dispositivo móvel do usuário e o hardware de borda posicionado no campo.

Fonte: Autoria própria.



Figura 36 – Tela de configuração da sessão de coleta automática, garantindo a indexação correta dos dados inferidos pelo algoritmo no banco de dados local.

Fonte: Autoria própria.