

**UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA**

MARIA DE FÁTIMA ARAÚJO ALVES

**VISÃO COMPUTACIONAL APLICADA A ANÁLISE DE PADRÕES E SINAIS
DO COMPORTAMENTO DE SUÍNOS EM AMBIENTE CLIMATIZADO**

**RECIFE/PE
2024**

MARIA DE FÁTIMA ARAÚJO ALVES

**VISÃO COMPUTACIONAL APLICADA A ANÁLISE DE PADRÕES E SINAIS
DO COMPORTAMENTO DE SUÍNOS EM AMBIENTE CLIMATIZADO**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola da Universidade Federal Rural de Pernambuco como parte dos requisitos para obtenção do título de Doutora em Engenharia Agrícola.

Orientador: Prof. Dr. Héilton Pandorfi

Coorientador: Prof. Dr. Ricardo Brauer Vigoderis

RECIFE/PE

2024

Dados Internacionais de Catalogação na Publicação
Sistema Integrado de Bibliotecas da UFRPE
Bibliotecário(a): Suely Manzi – CRB-4 809

A474v Alves, Maria de Fátima Araújo.
Visão computacional aplicada a análise de padrões e sinais do comportamento de suínos em ambiente climatizado / Maria de Fátima Araújo Alves. – Recife, 2024.
173 f.; il.

Orientador(a): Héilton Pandorfi.
Co-orientador(a): Ricardo Brauer Vigoderis.

Tese (Doutorado) – Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em Engenharia Agrícola, Recife, BR-PE, 2024.

Inclui referências.

1. Suínos - Comportamento. 2. Aprendizado do computador. 3. Processamento por imagem. 4. Visão por computador 5. Inteligência artificial. I. Pandorfi, Héilton, orient. II. Vigoderis, Ricardo Brauer, coorient. III. Título

MARIA DE FÁTIMA ARAÚJO ALVES

**VISÃO COMPUTACIONAL APLICADA A ANÁLISE DE PADRÕES E SINAIS
DO COMPORTAMENTO DE SUÍNOS EM AMBIENTE CLIMATIZADO**

BANCA EXAMINADORA

Prof. Dr. Héilton Pandorfi
Orientador - DEAGRI/UFRPE

Prof. Dr. Rodrigo Gabriel Ferreira Soares
Membro Externo – DEINFO/UFRPE

Profa. Dra. Silvia Helena Nogueira Turco
Membro Externo – UNIVASF

Prof. Dr. Gledson Luiz Pontes de Almeida
Membro Interno - DEAGRI/UFRPE

Profa. Dra. Cristiane Guiselini
Membro Interno - DEAGRI/UFRPE

AGRADECIMENTOS

Agradeço a Deus por me proteger, pela sua infinita bondade e misericórdia todos os dias.

À Universidade Federal Rural de Pernambuco - Departamento de Engenharia Agrícola, ao Programa de Pós-graduação em Engenharia Agrícola (PGEA) pela oportunidade de crescimento acadêmico e profissional.

À FACEPE (Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco), pela bolsa concedida.

A toda minha família, por todo companheirismo que existem entre nós, em especial à minha mãe, a meu pai *in memoriam*, aos meus seis irmãos e aos meus sobrinhos.

Ao meu Orientador, Prof. Dr. Héilton Pandorfi, pela orientação, paciência e ensinamentos.

Ao Departamento de Estatística e Informática (DEINFO), em especial ao professor Rodrigo Gabriel Ferreira Soares pelas contribuições.

A todos os professores do Programa de Pós-Graduação em Engenharia Agrícola, pelos ensinamentos.

Ao Grupo de Pesquisa em Ambiente (GPESA – UFRPE) pelo apoio, amizade e incentivo.

A todos que contribuíram direto e indiretamente para a realização desse trabalho.

**“... Tudo é possível àquele que crê”
Marcos 9:23**

RESUMO

O comportamento animal é um indicador potencial para caracterização do estado de bem-estar dos animais nos sistemas de produção. Os suínos possuem comportamentos que resultam da interação dos animais com as variáveis do ambiente. Nesse sentido, o objetivo desta pesquisa foi desenvolver uma metodologia sequencial para extração de características automáticas de imagens térmicas e a classificação de estresse térmico em suínos por meio de aprendizado de máquina e identificar padrões comportamentais de suínos em ambiente climatizado por meio de visão computacional. Foram obtidas imagens infravermelhas com auxílio de um termovisor FLIR E60, de 18 suínos alojados em baias climatizadas e não climatizadas e em seguida as imagens foram pré-processadas e aplicado o algoritmo de classificação de imagens para prever o conforto térmico dos animais. Também foram instaladas microcâmeras nas baias dos animais para a geração de vídeos, registrados simultaneamente a temperatura e a umidade do ar. Para reconhecer o comportamento de ficar em pé, deitar-se, comer e beber dos suínos foi treinado o YOLOv5 e em seguida o modelo foi usado para detectar os animais. Os resultados indicaram que utilizando Máquina de Suporte de Vetor (SVM) a pesquisa alcançou uma taxa de precisão de 80% na classificação automática de imagens térmicas de suínos em conforto e desconforto. Já no reconhecimento dos comportamentos de ficar em pé e deitar o YOLOv5 alcançou uma taxa de precisão média de 97,3% e revocação média de 96,1% e exibiu taxas de precisão média de 97,5% e recordação média de 97,0% no reconhecimento do comportamento alimentar e do consumo de água dos suínos. O método de segmentação baseado na cor obteve coeficiente de similaridade de 0,90, e o algoritmo proposto divergiu em apenas 0,80°C do programa de referência. O modelo de aprendizado de máquina alcançou 80% de precisão e 91% de acurácia na detecção de estados de conforto e desconforto térmico. O modelo YOLOv5 demonstrou alta eficiência na detecção de comportamentos de suínos, com uma precisão média de 97,3% e revocação média de 96,1%. Ele identificou variações comportamentais ligadas às condições micrometeorológicas nos alojamentos, mostrando que suínos em baias climatizadas passam mais tempo em pé e no comedouro.

Palavras-chave: Animais de produção. Aprendizado de máquina. Monitoramento inteligente

ABSTRACT

Animal behavior is a potential indicator for characterizing the welfare status of animals in production systems. Pigs have behaviors that result from the interaction of animals with environmental variables. In this sense, the objective of this research was to develop a sequential methodology for the extraction of automatic characteristics from thermal images and the classification of heat stress in pigs through machine learning and to identify behavioral patterns of pigs in an air-conditioned environment through computer vision. Infrared images were obtained, with the aid of a FLIR E60 thermal imager, of 18 pigs housed in air-conditioned and non-air-conditioned pens and then the images were pre-processed, and an image classification algorithm was applied to predict the thermal comfort of the animals. Micro cameras were also installed in the animals' stalls to generate videos, and the temperature and humidity of the air were simultaneously recorded. To recognize the behavior of standing, lying down, eating and drinking, the pigs were trained on the YOLOv5 and then the model was used to detect the animals. The results indicated that using Vector Support Machine (SVM) the research achieved an accuracy rate of 80% in the automatic classification of thermal images of pigs into comfort and discomfort. On the other hand, in the recognition of standing and lying down behaviors the YOLOv5 achieved an average accuracy rate of 97.3% and average recall of 96.1% and exhibited average accuracy rates of 97.5% and average recall of 97.0% in the recognition of pigs' feeding behavior and water consumption. The color-based segmentation method obtained a similarity coefficient of 0.90, and the proposed algorithm diverged by only 0.80°C from the reference program. The machine learning model achieved 80% accuracy and 91% accuracy in detecting states of comfort and thermal discomfort. The YOLOv5 model demonstrated high efficiency in detecting pig behaviors, with an average accuracy of 97.3% and average recall of 96.1%. He identified behavioral variations linked to the micrometeorological in the dwellings, showing that pigs in climate-controlled pens spend more time standing and in the feeder.

Key features: Machine learning. Production animals. Intelligent monitoring.

LISTA DE FIGURAS

Figura 1. Etapas básicas do processamento de imagens.....	34
Figura 2. Histograma por canal de cor: (A) imagem colorida e de imagem cinza (B)...	40
Figura 3. Esquema da Estrutura de uma Rede Neural Convolutacional Simples	50
Figura 4. Esquema do funcionamento do max-pooling com filtro 2x2.....	51
Figura 5. Matriz de confusão binária.....	52
Figura 6. Representação de matriz de confusão multi classe.	54
Figura 7. Diagrama da Estrutura do algoritmo yolov5	57
Figura 8. Localização da área de estudo.....	97
Figura 9. Fluxograma do algoritmo proposto.....	99
Figura 10. Medida do Índice de Similaridade Estrutural.....	107
Figura 11. Histograma da imagem original e da imagem aprimorada.	108
Figura 12. Remoção do canal H (a), filtro bilateral (b), filtro mediano (c) e equalização de histograma (d).....	109
Figura 13. Imagem original (a), imagem original em tons de cinza (b), canal H (c), filtro mediano (d), binarização de Otsu (e), pixels isolados (f), imagem binarizada invertida (g) e contorno (h).....	110
Figura 14. Imagem original (a), imagem original em tons de cinza (b), canal H (c), filtro mediano (d), binarização de Otsu (e), pixels isolados (f), imagem binarizada invertida (g) e contorno (h).....	111
Figura 15. Cores segmentadas (a), pixels extraídos (b), máscara (c) e contorno (d). ..	112
Figura 16. Imagem segmentada (a), imagem em cinza (b), máscara (c) e contorno (d).	112
Figura 17. Temperaturas superficiais médias para o ambiente climatizado obtidas via programa <i>ThermaCam</i> e algoritmo proposto (a). Regressão linear (b).....	115
Figura 18. Temperaturas superficiais médias para o ambiente sem climatizador (a). Regressão linear (b).....	116
Figura 19. Região de maior temperatura superficial detectada pelo algoritmo proposto.	118
Figura 20- Localização geográfica do local do experimento	135
Figura 21- Fluxograma da Etapa de Monitoração dos Animais	139
Figura 22. Processo de detecção dos comportamentos de deitar e ficar em pé.....	144
Figura 23. Reconhecimento do comportamento de comer e de beber.....	145

Figura 24. Reconhecimento do comportamento de comer e beber	146
Figura 25- Curva de treinamento: a) curva de perda de classe e b) precisão	154
Figura.26- Curva de perda de classe e mAP_05 na validação.....	155
Figura.27- Resultado das detecções do yolov5.	160
Figura.28- Monitoramento manual e estimado nas baias com climatização	161
Figura 29- Comportamentos no ambiente climatizado.....	162
Figura 30. Monitoramento manual e automático nas baias sem climatização	163
Figura 31. Comportamentos analisados no ambiente sem climatizadores	164
Figura 32. Ilustração da lona nas baias quentes.....	167
Figura 33- Monitoramento visual e automático da ingestão de alimentos nas baias ...	169

LISTA DE TABELAS

Tabela 1. Princípios e critérios para avaliação de qualidade de bem-estar animal.	26
Tabela 2- Temperaturas de referências para fases fisiológicas de suínos	27
Tabela 3. Indicadores de Conforto térmico	29
Tabela 4. Hiperparâmetros e espaço de busca do YOLOv5.....	62
Tabela 5. Valores inferiores e superiores do espaço HSV.	101
Tabela 6. Intensidade de cor e temperatura associada.....	101
Tabela 7. Métricas de avaliação para o desempenho das segmentações.	113
Tabela 8. Métricas de desempenho do algoritmo proposto para a extração de temperaturas das imagens térmicas.	115
Tabela 9. Estatística descritiva da temperatura superficial dos suínos.....	119
Tabela 10. Desempenho do classificador SVM.....	121
Tabela 11- Comportamento de suínos.	138
Tabela 12- Temperaturas e umidades relativas ótimas e críticas para suínos	138
Tabela 13- Frequência respiratória e Temperatura retal.....	138
Tabela 14- Classificação de ITGU para suínos	139
Tabela 15. Temperaturas e Umidades Relativa do Ar nas instalações.....	148
Tabela 16. Resultados das variáveis fisiológicas.....	150
Tabela 17. ITGU das baias	151
Tabela 18- Tamanho do modelo e duração do treinamento	153
Tabela 19- Métricas de avaliação no conjunto de teste do yolov5m.....	156
Tabela 20- Métricas de avaliação no conjunto de teste do yolov5s	157
Tabela 21. Métricas de avaliação no conjunto de teste do yolov5x	158
Tabela 22- Métricas de desempenho	165
Tabela 23- Ingestão de água dos animais nos ambientes estudados.....	166

SUMÁRIO

	Pág.
CAPÍTULO I	17
1.1 Introdução Geral	17
1.2 Objetivos	19
1.2.1 Geral	19
1.2.2 Específicos	19
1.3 Referencial Teórico	22
1.3.1 Legislação dirigida à produção de suínos	22
1.3.2 Bem-estar de suínos	23
1.3.3 Conforto térmico em instalações de suínos	26
1.3.4 Comportamento de suínos	29
1.3.5 A produção de suínos na segurança alimentar e sustentabilidade ambiental	32
1.3.6 Visão computacional	33
1.3.6.1 Aquisição de imagens	34
1.3.6.2 Pré-processamento	37
1.3.6.3 Segmentação de imagens	41
1.3.6.4 Extração de características	45
1.3.6.5 Reconhecimento e Interpretação	46
1.3.7 Redes Neurais Convolucionais - CNN	49
1.3.7.1 Métricas de Validação das Redes Neurais	51
1.3.8 Algoritmo YOLO (<i>You Only Look Once</i>)	55
1.3.8.1 Estrutura do Yolov5	56
1.3.8.2 Hiperparâmetros do YOLOv5	60
1.3.8.3 Métricas de avaliação do YOLOv5	65
1.3.9 Aplicação do aprendizado de máquina na produção suína	66
Referências	70
CAPÍTULO II	92
2.1 Introdução	93
2.2 Material e métodos	96
2.2.1 Localização e caracterização da área de estudo	96
2.2.2 Coleta de dados	97
2.2.2.1. Registro das imagens térmicas	97

2.2.2.2 Registro das variáveis ambientais _____	98
2.2.3 Ferramenta utilizada _____	99
2.2.3.1 Pré-processamento _____	99
2.2.3.2 Segmentação _____	100
2.2.3.3 Extração de características _____	103
2.2.3.4 Reconhecimento e Interpretação - Classificador _____	105
2.3 Resultados e Discussão _____	106
2.3.1 Pré-processamento _____	106
2.3.1.2. Segmentação pelo método Otsu _____	110
2.3.1.3 Segmentação por cor _____	111
2.3.1.4 Métricas de avaliação para as segmentações _____	112
2.3.2 Extração de características _____	114
2.3.3 Avaliação do conforto térmico _____	119
2.3.4 Classificador _____	121
2.4 Conclusões _____	123
Referências _____	123
CAPÍTULO III _____	130
3.1 Introdução _____	131
3.2 Material e métodos _____	134
3.2.1 Localização do experimento _____	134
3.2.2 Instalações _____	135
3.2.3 Experimento _____	135
3.2.4 Coleta de variáveis _____	136
3.2.4.1 Variáveis meteorológicas _____	136
3.2.4.2 Variáveis fisiológicas _____	136
3.2.4.3 Variáveis comportamentais _____	137
3.2.5 Procedimento metodológico _____	138
3.2.5.1 Avaliação do conforto térmico dos animais _____	138
3.2.5.2 Monitoramento do comportamento dos animais _____	139
3.2.5.3 Implementação do algoritmo _____	141
3.2.5.3.1 Avaliação do desempenho do modelo _____	143
3.2.5.4 Reconhecimento da ingestão de ficar em pé e se deitar _____	144
3.2.5.5 Reconhecimento da ingestão de alimentos e de água _____	145
3.3 Resultados e discussão _____	148

3.3.1 Análise do ambiente dos animais _____	148
3.3.2 Análise das Variáveis fisiológicas _____	150
3.3.3 Monitoramento do comportamento dos animais _____	152
3.3.3.1 Configuração experimental _____	152
3.3.3.2 Avaliação do desempenho do modelo _____	156
3.3.3.3 Identificação de padrões de comportamento nos suínos _____	161
3.3.4 Comportamento de comer e beber _____	165
3.4. Conclusões _____	170
Referências _____	171

CAPÍTULO I

INTRODUÇÃO GERAL E REVISÃO DE LITERATURA

1.1 Introdução Geral

O comportamento animal é um indicador potencial para caracterização do estado de bem-estar dos animais nos sistemas de produção (PARREIRA et al., 2021). Considerado também como um indicador da sensação térmica dos animais (CARVALHO et al., 2021). Cagliari et al. (2021) também ressaltam que o comportamento dos animais resulta da interação dos animais com as variáveis do ambiente.

Lima et al. (2022) expõem que os animais expressam comportamentos a todo instante e que tais comportamentos não são aleatórios e a frequência relativa com que os comportamentos ocorrem e a sua duração podem ser estimados através de amostragens observacionais. Ferreira et al. (2022) revelam que tais comportamentos podem ser avaliados por um etograma, que é um inventário de comportamentos, empregado em várias pesquisas de análise comportamental de suínos. Desse modo, o comportamento pode ser avaliado como resposta confiável ao bem-estar animal (RODRIGUES et al., 2021). Araújo; Guimarães e Gomes (2022) ressaltam que o comportamento animal pode ser avaliado de forma qualitativa, para observar, descrever e categorizar os comportamentos e de forma quantitativa, em que os comportamentos são mensurados em intervalos de tempo.

Os comportamentos vitais que mantêm relação com as características micrometeorológicas do ambiente são comer e beber (RODRIGUES et al., 2021). Kiefer et al. (2010) constataram que os animais submetidos ao estresse térmico passaram mais tempo deitados e ingeriram menos alimento, repercutindo negativamente no seu desempenho e Silva et al. (2023a) narram que suínos provocados por temperaturas elevadas ingerem mais água. Carvalho et al. (2021) citam que suínos deitados em decúbito lateral aumentam a área de contato com o piso para dissipar calor sensível, entretanto, aumentam a área usada quando comparado a postura externa. No frio, os suínos evitam correntes de ar e ficam próximos uns dos outros para aumentar a temperatura corporal e em temperaturas elevadas, os animais se mantêm afastados e próximos a ambientes úmidos, como excrementos, lama, lâminas de água, entre outros (KRÜGER e LINK, 2023).

Dessa forma, avaliar o comportamento dos animais é importante para a produção da suinocultura. Tal avaliação pode ser feita de três formas: visualização direta, em que o avaliador está presente no ambiente do animal, sendo essa forma de observar e registrar o comportamento é demorada, imprecisa e gera incômodo aos animais, devido a presença

do homem no ambiente; a visualização indireta, em que o avaliador instala câmeras de vídeos nos estabelecimentos dos animais e depois analisa os vídeos através de observação visual; e atualmente, o método de visão computacional, que utiliza inteligência artificial para identificar e interpretar padrões de comportamentos, sendo apresentado os indicadores em tempo real e sem interferência do avaliador (DALLABRIDA et al., 2023).

Muitos recursos estão sendo utilizados para avaliar os comportamentos dos suínos, como chips, etiquetas auriculares, transponders e imagens térmicas, os quais tem avançado significativamente com o advento de tecnologias inovadoras. A integração de novos fluxos de dados provenientes de diferentes fontes, como observações rotineiras de produtores, veterinários, laboratórios de diagnóstico e inspetores de abatedouros, tem permitido o desenvolvimento de sistemas de vigilância de doenças mais eficazes (GATES et al., 2015).

A utilização de transponders implantáveis, sensores de temperatura e sistemas de rastreamento automatizado tem permitido monitorar o comportamento dos suínos de forma contínua e precisa, possibilitando a detecção precoce de alterações comportamentais que podem indicar problemas de saúde ou bem-estar, no entanto são técnicas invasivas (MATTHEWS et al., 2017).

Em substituição às técnicas invasivas, a aplicação de tecnologias inteligentes baseadas em sensores inteligentes e IoT, tem se mostrado uma estratégia sustentável e eficaz na modernização da suinocultura (MAHFUZ et al., 2022). Esses avanços tecnológicos possibilitam a coleta, processamento e análise de dados de forma mais eficiente, contribuindo para a saúde, bem-estar e produtividade dos rebanhos suínos (RACEWICZ et al., 2021) e isso reflete um avanço significativo na indústria pecuária, permitindo uma gestão mais eficiente e sustentável dos rebanhos. A integração de sistemas inteligentes, sensores avançados e métodos não invasivos de coleta de dados tem contribuído para a promoção da saúde, bem-estar e produtividade dos suínos, demonstrando o potencial dessas inovações para o futuro da suinocultura.

Portanto, considerando que os indicadores comportamentais podem ser obtidos em tempo real por meio de métodos de visão computacional, entre os quais pode-se citar os modelos baseados em Aprendizagem Profunda de Máquina (*Deep Learning*) demonstram potencial para identificação de padrões em vídeo e imagens, em substituição as observações tradicionais (WANG et al., 2023a).

1.2 Objetivos

1.2.1 Geral

Analisar aspectos quantitativos e qualitativos do comportamento de suínos nas fases de crescimento e terminação, submetidos à climatização integrados a determinação de sinais e padrões por meio da visão computacional.

1.2.2 Específicos

- Desenvolver uma metodologia sequencial para extração de características automáticas de imagens térmicas e classificação de estresse térmico de suínos por meio do aprendizado de máquina;
- Desenvolver sistema computacional para caracterização do comportamento de suínos submetidos aos manejos específicos de adequação térmica do ambiente de criação.

1.3 Referencial Teórico

1.3.1 Legislação dirigida à produção de suínos

No âmbito internacional, a União Europeia se destaca no que se refere a proteção aos animais, exigindo que toda a cadeia produtiva - produção, transporte e abate - seja evitado ao máximo o sofrimento desnecessário (CARVALHO et al., 2021). Essas exigências são expostas em regulamentos obrigatórios em todo território e aplicadas em cada estado. As diretrizes normatizam os estados membros a aplicarem os procedimentos e buscarem os resultados desejados, sendo papel das autoridades nacionais a eleição da forma e dos meios para alcançá-los (CASTRO LIPPI et al., 2022).

As principais legislações europeias são a diretiva 98/58/CE que está relacionada a proteção dos animais de produção (durante a produção, transporte e abate), não apenas de suínos, obrigando que o proprietário do animal tome todas as medidas adequadas para assegurar o bem-estar com objetivo de garantir que não sofram dores ou outros danos propositais e a diretiva 2008/120/CE que é específica para suínos, englobando os requisitos mínimos de alojamento para leitões de creche, suínos com mais de 10 semanas de idade até o abate e porcas e leitoas após a cobertura, além de exigir o piso de concreto com terço final vazado para os ambientes de alojamentos (CARVALHO et al., 2021).

Para assegurar a segurança dos animais durante o transporte, foi elaborado o regulamento (CE) nº 1/2005 em que é exigido o uso de aparelhos que administram descargas elétricas nos manejos relacionados durante todo o deslocamento (GALDIOLI et al., 2022).

Para o abate, a União Europeia criou o regulamento (CE) nº 1099/2009 que exige métodos de insensibilização (SINDHOJ et al., 2021). Além disso, o Canadá também emitiu uma publicação do Código de Boas Práticas de Suínos em 2014, a Nova Zelândia em 2015, a Austrália em 2017, em que relataram a proibição de projetos de granjas com gaiolas individuais mantendo o prazo para adequações dos sistemas de alojamento até 2024. A África do Sul em 2020, também defendeu que pretende obedecer a essa proibição (CASTRO LIPPI et al., 2022).

Dessa forma, conforme Vilas-Boas; Klerkx e Lie (2022), nos últimos anos, foram estabelecidos acordos internacionais para disseminar padrões de bem-estar animal globalmente, em paralelo aos padrões de sustentabilidade ambiental e social.

Quanto a legislação brasileira, o Ministério da Agricultura, Pecuária e Abastecimento (MAPA) é o órgão responsável pelas ações voltadas para as questões do

bem-estar animal (CARVALHO et al., 2021). Desde a década de 2000, no Brasil, as preocupações com o bem-estar animal desencadearam alterações específicas no sistema nacional de produção comercial de suínos, especialmente no que se refere ao transporte, abate e manejo dos leitões (VILAS-BOAS; KLERKX e LIE, 2022). Em 2013, o Brasil assinou um acordo de cooperação técnica com a União Europeia para implementar regulamentações internacionais de bem-estar animal, resultando em alterações importantes na produção suína brasileira (VILAS-BOAS; KLERKX e LIE, 2022).

Em 2020 no Brasil, foi criada a primeira legislação acerca do bem-estar de suínos, a qual entrou em vigor em 1º de fevereiro de 2021 e, a Instrução Normativa (IN) nº 113 que estabeleceu novas regras sobre as boas práticas de manejo e bem-estar animal nas granjas de suínos de criação comercial, impondo prazos e datas limites aos produtores (CARVALHO et al., 2021). Com essa IN no Brasil, as granjas de suínos têm até 1º de janeiro de 2045 para se regularizarem, implementando medidas que diminuam o estresse dos animais e fica proibido adotar condutas agressivas, tais como chutes, arraste de animais conscientes, elevação ou puxão pelas orelhas, rabo ou outras partes sensíveis (NETA et al., 2021).

1.3.2 Bem-estar de suínos

A carne suína lidera o consumo global de proteína animal, colocando o Brasil em quarto lugar mundial atualmente. A suinocultura destaca-se como um setor da pecuária com desempenho financeiro relevante. Dada essa importância, é necessário que os procedimentos de abate sigam padrões rigorosos, assegurando a produção de carcaças de alta qualidade. Diante desse cenário, os suínos são cada vez mais submetidos a condições de criação intensiva, onde qualquer falha durante o processo pode acarretar prejuízos significativos à cadeia produtiva (MATOS et al., 2022).

No âmbito das principais exigências dos consumidores de proteína animal, está a garantia do bem-estar dos animais confinados, pois a busca por produtos de qualidade e procedência conhecida aumentou consideravelmente e os consumidores estão mais atentos a qualidade de vida dentro do ambiente onde esses animais são criados, demandando a aplicação de ações éticas junto aos sistemas que são designados à produção animal (BRADFORD et al., 2022).

Com esse aumento na produção de suínos, o conforto e o bem-estar animal, vem sofrendo alterações, seja por redução do seu espaço, prejudicando a movimentação ou ainda as mudanças nas interações sociais, podendo assim, colaborar para o surgimento de

problemas referentes ao conforto térmico e consequentemente a sua produtividade, exigindo que os criadores ampliem o controle no manejo dos rebanhos para obter uma produção favorável (CARVALHO et al., 2021).

Nesse cenário, o número de pesquisas sobre o bem-estar dos suínos aumentou e proporcionou ao longo do tempo benefícios inegáveis no sistema de produção animal, como a redução de morbilidade e mortalidade; influência na resistência dos animais a patologias; agregação de valor ao produto; aumento da qualidade do produto, pois sabe-se que os estados físico e mental do animal podem atuar direta e/ou indiretamente nas propriedades organolépticas do produto (LAWRENCE; NEWBERRY e ŠPINKA, 2024).

A produção intensificada é vantajosa para o produtor do ponto de vista econômico, porém, no contexto do bem-estar animal, o sistema intensivo traz diversos prejuízos que podem vir a desfavorecer a lucratividade da atividade. Isto porque intensificar exige otimização, seja de espaço, mão de obra e/ou outros recursos afins, ou seja, maior produtividade com menor custo (MAES et al., 2020).

Quanto ao significado de bem-estar animal, o Código Sanitário de Animais Terrestres OIE - Organização Internacional de Epizootias (2019), define como sendo o estado físico e mental de um animal em relação às condições em que este vive e morre. Para Okinda et al. (2020) o bem-estar animal é um tema político com complexidades, dinâmico com dimensões econômicas, científicas e éticas e precisam ser abordadas de forma objetiva e com enfoque técnico-científico. Já para Monteiro et al. (2023) o bem-estar animal refere-se ao estado atual em que um animal se encontra, considerando os seus estados físicos, mentais e sociais.

O relatório de Brambell descreveu pela primeira vez sobre as cinco medidas (liberdades) para manter os animais livres de condições prejudiciais ao seu bem-estar (REIMERT et al., 2023). Segundo a OIE - Organização Internacional de Epizootias (2019) em 1965 se definiu essas cinco liberdades como sendo a ausência de fome, desnutrição e sede; a liberdade de medo e angústia; a ausência de estresse causado pelo calor ou desconforto físico; livre de dor, lesão e doença; e liberdade para expressar padrões normais de comportamento.

A liberdade nutricional garante aos animais acesso ao alimento e à água de boa qualidade e em quantidade suficiente para o seu desenvolvimento, evitando assim desidratação, obesidade ou peso abaixo do ideal para a respectiva idade e estado fisiológico (CAGLIARI et al., 2021).

A liberdade de medo e angústia, segundo Souza; Guimarães e Pereira (2023) se refere a necessidade de evitar que os animais passem por situações que lhes causem danos psicológicos, como por exemplo, durante o transporte que devem serem utilizados veículos adaptados para cada espécie, densidade correta de animais dentro dos veículos, uso de piso antiderrapante, melhor controle da temperatura e da ventilação em caminhões fechados, treinamento de condutores, entre outras.

A liberdade sanitária garante a prevenção de doenças, sendo a principal medida necessária preventiva, a vacinação e para evitar dor em procedimentos invasivos como castração de animais em produção o uso de anestésias (CAGLIARI et al., 2021).

A liberdade de estresse, se refere a proteção desses animais em seus abrigos, onde eles devem estarem protegidos das intempéries climáticas, livres do sol, da chuva e da radiação direta, abrigados em instalações construídas com materiais adequados (telhado, piso), apropriados ao ambiente e à espécie para evitar desconforto térmico por frio ou por calor, com densidade adequada (sem superlotação), para permitir movimentação normal e interação com os outros animais (VAZ et al., 2022).

O desconforto dos animais pode ser causado por variáveis ambientais que agem alterando as respostas fisiológicas dos animais, interferindo no desempenho produtivo, podendo causar perdas econômicas para o produtor, principalmente em regiões tropicais como, temperatura, umidade do ar e a radiação solar direta (HU et al., 2023a).

A maioria dos animais de produção possuem a capacidade de regular a temperatura corporal perante o ambiente, processo conhecido como homeotermia e o suíno apresenta dificuldades para dissipar calor em ambiente com temperaturas elevadas e alta umidade do ar, pois o excesso de umidade reduz perdas evaporativas pela respiração e contribuir para diminuir o apetite, pois suas glândulas sudoríparas não realizam a manutenção da temperatura corporal (GÓMEZ-PRADO et al., 2022). Dessa forma, quando os suínos não conseguem realizar a dissipação de calor, os animais sofrem com estresse térmico e mudanças comportamentais se manifestam como sendo os principais indicadores de desconforto e ausência de bem-estar, diminuindo a ingestão de alimento e aumentando o consumo de água (RAMIREZ et al., 2022a).

As instalações de suínos diferem entre si, por isso é preciso guiar as práticas de manejo nos diferentes setores, considerando o bem-estar animal da forma mais viável em conformidade com a realidade da granja, objetivando garantir o lucro da atividade, buscar inserir novas tecnologias, respeitando os aspectos do bem-estar animal e oferecer um produto seguro e de qualidade ao consumidor final (MONTEIRO et al., 2023).

Voogt et al. (2023) citam que essas cinco liberdades são utilizadas para avaliar o bem-estar animal com base em investigação do ambiente de criação, voltados aos indicadores ou recursos que normalmente constituem o ambiente físico, ao invés de resultados ou indicadores baseados pontualmente ao estado do animal. Assim, recentemente, o interesse pelo desenvolvimento de bioindicadores vem crescendo e o ponto de vista de especialistas confirma que medidas baseadas em animais são mais apropriadas para determinação do bem-estar animal (MARCONE et al., 2022).

O projeto Welfare Quality, iniciado em 2004 e finalizado em 2009, baseia-se em quatro critérios para definir o bem-estar-animal (MONTEIRO et al., 2023; LAWRENCE; NEWBERRY e ŠPINKA, 2024), os quais se encontram dispostos na Tabela 1.

Tabela 1. Princípios e critérios para avaliação de qualidade de bem-estar animal.

Princípios de bem-estar	Crítérios de bem-estar
Boa alimentação	Ausência de fome prolongada Ausência de sede prolongada
Boa habitação	Conforto para descansar Conforto térmico Facilidade de movimento
Boa saúde	Ausência de lesões Ausência de doença Ausência de dor induzida por procedimentos de gestão
Comportamento apropriado	Expressão de comportamentos sociais Expressão de outros comportamentos Boa relação humano-animal Estado emocional positivo

Fonte: Monteiro et al. (2023) e Lawrence et al. (2024).

Dessa forma, o bem-estar é a resposta comportamental e ou fisiológica de um animal quando este tentar adaptar-se, consecutivamente a um ambiente, e assim sendo não é possível oferecer bem-estar ao animal, mas pode-se oferecer as condições necessárias à sua adaptação no ambiente (ARNDT; GOERLICH e VAN, 2022).

1.3.3 Conforto térmico em instalações de suínos

As informações climáticas que caracterizam o ambiente de confinamento de suínos, são a temperatura do ar, umidade relativa do ar, velocidade do vento e a radiação solar (BAËTA, 1997). A temperatura e a umidade do ar representam os principais elementos meteorológicos que impactam a produção suína, uma vez que as variações de temperatura exercem influência significativa no bem-estar dos suínos (LI et al., 2023).

Nas instalações de suínos, as variações de temperatura devem obedecer às faixas requeridas pelos animais de acordo com suas diferentes fases de vida, conforme discutido por Perdomo et al. (1985) (Tabela 2).

Tabela 2- Temperaturas de referências para fases fisiológicas de suínos

Categories	T. de conforto (°C)	T. crítica inferior (°C)	T. crítica superior (°C)	Umidade Relativa do Ar Ótima (%)
Recém-nascidos	32-34	-	-	70
Leitões até a desmama	29-31	21	36	70
Animais de creche	22-26	17	27	50 - 70
Leitões em crescimento	18-20	15	26	50 - 70
Suínos em terminação	12-21	12	26	50 - 70
Fêmeas gestantes	16-19	10	24	50 - 70
Fêmeas em lactação	12-16	7	23	50 - 70
Fêmeas vazias e machos	17-21	10	25	50 - 70

Fonte: Adaptado de Perdomo et al. (1985).

Elevadas temperaturas ambientes têm o potencial de aumentar de maneira significativa as taxas de incidência de mortalidade em suínos, comprometendo o bem-estar animal e acarretando perdas econômicas substanciais (WANG et al., 2023b). Em condições em que a temperatura ambiente ultrapassa a temperatura de conforto, os suínos adaptam sua produção de calor e consumo de energia para mitigar os impactos do estresse térmico (SEIDEL et al., 2020).

A prolongada exposição a temperaturas elevadas tem o potencial de suprimir a resposta imunológica dos suínos, desequilibrar seu estado térmico e resultar em condições graves, incluindo insolação, coma e até mesmo a morte (KIM et al., 2021).

Temperaturas e umidade elevadas afetam negativamente as variáveis fisiológicas dos suínos, como a temperatura retal, superficial e a frequência respiratória promovendo o estresse (SEIDEL et al., 2020). A temperatura retal nos suínos quando submetidos em ambientes confortáveis situa-se entre 38,5 e 39°C (SOUZA, 2004). A temperatura corporal normal dos suínos oscila entre 37,8 e 38,5°C, e a frequência respiratória em suínos adultos em conforto deve oscilar entre 15 a 25 mov. min⁻¹ (Yan e Yamamoto, 2000).

A umidade relativa do ar nas instalações dos animais se apresenta como fator importante para facilitar ou dificultar os mecanismos de dissipação de calor por via evaporativa. Segundo Bortolozzo et al. (2011) a faixa de umidade relativa do ar adequada para suínos é de 40 a 70%. Sampaio et al. (2004) alerta que a umidade relativa ideal é de

50 a 70% e não deve ultrapassar 70%. Já a velocidade do vento ameniza o calor no ambiente e ajuda na dissipação da umidade, poeira e dos gases gerados nas instalações pelos próprios animais (HU et al., 2023b).

Portanto, as variáveis meteorológicas podem atuar como agentes estressores, agravando o quadro de estresse térmico. O estresse térmico (HS) é uma ameaça à produtividade, saúde e bem-estar dos suínos (JOHNSON et al., 2020). Esses elementos meteorológicos nos alojamentos possuem efeitos na produção de suínos de forma direta e indireta, provocando à redução da produtividade e perdas econômicas para os produtores (PANDORFI; SILVA e PIEDADE, 2008).

As condições térmicas dos alojamentos é um fator importante e determinante para a boa produtividade dos suínos. Uma vez que, a pouca capacidade de regulação térmica destes acaba por provocar perda de calor de forma mais crítica, logo, quando ocorre a queda de temperatura, os suínos se esforçam para aumentar sua produção de calor, isso acontece por meio da termogênese, tremores musculares involuntários, metabolismo e mudanças comportamentais, proporcionando assim, através da sua postura, a identificação de condições de conforto ou estresse térmico em seu ambiente de criação (RAMIREZ et al., 2022b).

Gomes et al. (2018) desenvolveram uma pesquisa na qual caracterizaram o conforto térmico em instalações, verificando a influência de 2 sistemas de climatização, como resultados observaram que as baias com sistema de resfriamento adiabático evaporativo apresentaram temperaturas dentro da faixa ótima para os animais durante o dia reduzindo a temperatura até 0,9°C, enquanto as instalações com os ventiladores não apresentaram o mesmo desempenho, mas atenuaram em até 0,5°C as temperaturas no interior da instalação.

O ambiente térmico é avaliado por meio de indicadores de conforto térmico (MOTA et al., 2019). Os principais índices utilizados são o Índice de Temperatura do Globo Negro e Umidade (ITGU); o Índice de Temperatura e Umidade (ITU); a Carga Térmica Radiante (CTR) e a entalpia indicando a quantidade de energia térmica do ambiente (COSTA et al., 2023a).

A utilização desses índices ambientais tem sido fundamental na quantificação do conforto e desconforto térmico nos animais nas instalações, avaliando assim o impacto do ambiente nos animais. Ao utilizar estes índices, torna-se possível avaliar as condições térmicas vividas pelos animais, o que é essencial para garantir o seu bem-estar e produtividade, particularmente em condições climáticas desafiadoras. A avaliação destes

índices é vital para a implementação de medidas que mitiguem o estresse térmico e promovam o bem-estar dos animais de produção (CANESCHI et al., 2023).

O ITGU e a CTR utilizam como variáveis de entrada a temperatura do globo negro (TGN), enquanto o ITU utiliza a temperatura do ar (TAR). E a entalpia, tem como variáveis de entrada a temperatura de bulbo seco, a umidade relativa do ar e a pressão barométrica local (LEMOS et al., 2023).

Nos ambientes confinados, é recomendado avaliar o conforto térmico por meio do ITU, pois a carga térmica da radiação é desprezada nesse índice, uma vez que os ambientes são cobertos reduzindo os efeitos da radiação (FERNANDO et al., 2022).

Tanto o ITU quanto o ITGU avaliam o ambiente por meio de uma única variável, com distintas faixas de classificação, conforme indicado por Baêta e Souza (2010) e explícitos na Tabela 3.

Tabela 3. Indicadores de Conforto térmico

Classificação	ITU	ITGU
Conforto	até 70	até 74
Crítico	71 a 78	74 a 78
Perigoso	79 a 83	79 a 84
Emergência	> 83	> 84

Fonte: BAÊTA; SOUZA (2010).

Dessa forma, o estudo desses índices permite avaliar se determinado ambiente é favorável ou não para produção animal (BRITO et al., 2020) e prever os períodos em que há necessidade de implementar medidas para manter o bem-estar dos animais em determinadas época do ano. Segundo Araújo; Guimarães e Gomes (2022) tais estudos também podem indicar diagnósticos sobre perda de produtividade decorrentes dos elementos climáticos.

1.3.4 Comportamento de suínos

A parte da ciência que estuda o comportamento dos animais é a etologia, esses estudos mostram-se de extrema importância para o setor de produção de animal, uma vez que, a qualidade de vida e o bem-estar desses animais que se encontram em confinamento é de grande interesse para os consumidores (ALMEIDA et al., 2022).

O comportamento dos animais foi definido como sendo a forma de interação dos animais com o ambiente ao qual eles estão inseridos, ou seja, é a expressão da união entre o organismo e o ambiente (CAGLIARI et al., 2021). Chapa et al. (2020) monitoraram o comportamento dos animais observando as atividades que estes desenvolveram no

alojamento, como animais consumindo ração no comedouro (comendo), em pé parado ou se locomovendo pela baia; deitado acordado ou dormindo e animal sobre lâmina d'água em pé ou deitado e conseguem identificar o bem-estar animal e a saúde do rebanho.

Para Neethirajan; Reimert e Kemp (2021), o bem-estar animal precisa ser considerado durante todo o ciclo de vida dos suínos, com práticas de manejo que minimizem os distúrbios, pois é através disso que se pode analisar o comportamento dos animais. Nesse caso, se faz necessário monitorar os animais e conhecer o que observar e qual ferramenta utilizar para esse monitoramento. Ferrari e Camargo (2023) apontam o etograma como sendo uma ferramenta eficaz, utilizada em várias pesquisas para análise comportamental dos suínos. Gomes et al. (2019) utilizaram o etograma para analisar as variáveis comportamentais de suínos em fase de terminação.

Cagliari et al. (2021) ressaltaram que o comportamento animal é resultado da interação do animal com o ambiente e são duas etapas para se fazer análise do comportamento, uma qualitativa para observar, descrever e categorizar os comportamentos e uma fase quantitativa, em que os comportamentos serão mensurados em intervalos de tempo.

O comportamento dos suínos pode ser analisado por meio de indicadores, os quais são descritos como indicadores de bem-estar, indicadores fisiológicos, indicadores comportamentais e de ambientes (GUEVARA et al., 2022). Na pesquisa conduzida por Guevara et al. (2022), que analisou o número de artigos investigando os indicadores fisiológicos dos animais para prever o conforto térmico, constatou-se que a temperatura retal foi o método de medição mais amplamente empregado, sendo mencionado em 85 manuscritos como indicador de estresse térmico. A avaliação da frequência respiratória ocupou o segundo lugar, mencionada em 76 artigos, como um indicador frequente para medir o estresse térmico. Como indicadores comportamentais foram relatados o monitoramento do comportamento dos animais em vídeos em 8 artigos e os indicadores ambientais foram o ITU em 22 artigos, a termografia infravermelha sem contato em 24 artigos.

O comportamento dos suínos pode prever o seu bem-estar (PANDORFI et al., 2020), podendo precocemente revelar doenças ou situações de desconforto (MAHFUZ et al., 2022). Para Habineza et al. (2021), a detecção precoce de doenças é uma maneira eficiente de evitar surtos de doenças em larga escala e perdas econômicas para o produtor.

No entanto, monitorar tais comportamentos pelos métodos tradicionais podem ser desgastantes para os humanos e para os animais, interferindo no seu desenvolvimento

(SHAO; PU e MU, 2021). Além disso, podem ser falhosas e não retratar com precisão o verdadeiro diagnóstico da saúde dos animais (SHAO; PU e MU, 2021). Conforme Sadeghi et al. (2023) a realização do processo de observação visual no monitoramento animal pode ser bastante demorada quando aplicada a um rebanho extenso.

O emprego de novas tecnologias na pecuária, oferece a possibilidade de avaliação contínua da saúde e do bem-estar animal. A aplicação de algoritmos computacionais proporciona uma interpretação mais confiável dos dados sensoriais, teoricamente permitindo a detecção da maioria das doenças ou problemas potenciais e alertando os agricultores para evitar impactos negativos no bem-estar animal e prejuízos econômicos (SADEGHI et al., 2023).

Na indústria suína, monitorar o comportamento do rebanho é primordial para avaliar a saúde dos animais, destacando a necessidade de introduzir ferramentas inteligentes para o monitoramento remoto dos suínos e a entrega precisa de informações aos operadores da fazenda (PANDEY et al., 2021).

A análise do comportamento animal é importante para analisar a resposta dos animais com o ambiente aos quais foram submetidos. De acordo com Perdomo; Kozen; Sobestiansky e Silva (1985) os suínos podem expressar seu comportamento de acordo com o ambiente em que vive como respostas fisiológicas. Dessa forma, basta monitorar seus comportamentos e associar com sua saúde, elementos climáticos aos quais estão submetidos e de forma geral ao seu bem-estar.

O principal comportamento analisado é a atividade de comer, pois, segundo Alameer; Kyriazakis e Bacardit (2020) é o principal indicador para avaliar a saúde e o bem-estar de suínos. Em ambientes quentes, os animais reduzem o consumo de ração e a duração das visitas aos comedouros (OLIVEIRA et al., 2023). Na pesquisa de Oliveira et al. (2023) os suínos submetidos a estresse térmico apresentaram menor consumo diário de ração e conseqüentemente os menores pesos corporais, associado a maior ingestão de água. Na revisão de pesquisa conduzida por Bus et al. (2021), a análise do consumo de ração em condições de estresse térmico revelou que, em 10 artigos revisados, todos os estudos indicaram uma redução no consumo de ração por parte dos suínos durante essas condições. Além disso, foi observado que suínos clinicamente doentes tendem a apresentar um consumo de ração inferior, em comparação aos suínos saudáveis, enquanto suínos mais velhos demonstraram uma diminuição no consumo alimentar.

O comportamento de deitar pode ser um indicativo do cenário de conforto ou desconforto térmico. Suínos deitados amontoados mostram características de um

ambiente frio, suínos deitados estirados demonstram comportamentos observados em ambiente quente (SILVA et al., 2023a). Kiefer et al. (2010) afirmaram que os suínos quando confinados em um ambiente confortável passam a maior parte do tempo descansando e dormindo, podendo chegar a 19 horas/dia, ou dormir mais que 80% do seu tempo.

1.3.5 A produção de suínos na segurança alimentar e sustentabilidade ambiental

De acordo com Ferreira et al. (2017), o Brasil apresenta um alto potencial para o consumo de carne suína, uma vez que 74% da produção nacional é consumida internamente. De acordo com Machado et al. (2020) é necessário garantir esse consumo.

A garantia da produção de carne suína depende de muitos fatores, sendo que os principais estão relacionados ao bem-estar animal. O conforto térmico dos animais e o manejo são primordiais, podendo ser mensurados por meios de variáveis ambientais e animais. Sendo assim, a análise do comportamento dos suínos reflete o gerenciamento da atividade e ajuda a minimizar seus impactos negativos (FERRARI et al., 2023).

Os animais em estresse calórico apresentam perda de desempenho e conseqüentemente redução da disponibilidade de carne para o mercado, geram resíduos sólidos e líquidos e o consumo excessivo de recursos ambientais (FELIPE et al., 2020).

O monitoramento da atividade suína contribui para melhorar o desempenho dos animais e contribuir para a disponibilidade de alimentos. Isso, por sua vez, contribui para aumentar a disponibilidade de alimentos e enquadra a produção com os Objetivos de Desenvolvimento Sustentável (ODS), especialmente ODS 2 que é acabar com a fome, alcançar a segurança alimentar, melhorar a nutrição e promover a agricultura sustentável; e ODS 13 que é tomar medidas urgentes para combater a mudança climática e seus impactos, voltados para a segurança alimentar e a gestão sustentável dos recursos.

Ao implementar o ODS 2 na produção de suínos com ênfase no conforto térmico, não apenas se busca assegurar a segurança alimentar e a nutrição adequada, mas também se colhem benefícios adicionais, como economia de recursos, tais como energia e água. Isso significa que não só estamos melhorando a oferta de alimentos, mas também promovendo práticas sustentáveis, que minimizam o impacto ambiental e contribuem para a luta contra as mudanças climáticas, em linha com os objetivos do ODS 13. Portanto, ao monitorar de perto a produção suína e implementar medidas sustentáveis, estamos atendendo às necessidades presentes na garantia de um futuro mais seguro e sustentável para todos. No entanto, segundo a Embrapa (2020) o setor agropecuário,

principalmente as atuais preocupações com o bem-estar animal, em especial dos animais domésticos de interesse econômico, contribuem para a sustentabilidade ambiental, social e econômica e, conseqüentemente, estão inter-relacionadas com todos os ODS da Agenda 2030.

1.3.6 Visão computacional

A visão computacional são técnicas para que máquinas consigam interpretar e compreender o mundo por meio de imagens ou vídeos, ela faz com que os computadores imitem humanos e, portanto, utiliza o conceito de visão humana (FERNANDES; DÓREA e ROSA, 2020a; SILVA et al., 2020; SILVA e MARTINS, 2023).

Para processar imagens digitais e extrair as informações desejadas, uma série de algoritmos especializados são empregados. Esses algoritmos são projetados para capturar, pré-processar e aprimorar atributos da imagem antes de aplicar diversas técnicas para propósitos distintos (GÜNTHER et al., 2023)).

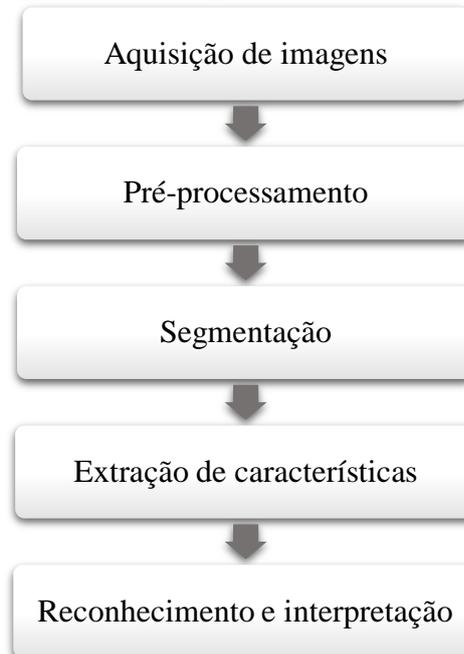
O pré-processamento de imagens ocorre de duas áreas basilares: melhoria da informação visual para interpretação humana e o processamento de dados para a percepção automática através de máquinas. As imagens podem estar associadas, por exemplo, a um determinado fenômeno físico. Logo, processá-las, possibilitará a efetivação de operações matemáticas com o objetivo de extrair informações (JOHN e JOSEPH, 2023). O pré-processamento de imagens é extremamente complexo, razão da não existência até o momento de uma solução única e com abrangência para todos os problemas, criando espaços para novas pesquisas (HE et al., 2024).

Cabe destacar que um dos interesses imprescindíveis no campo de processamento de imagem corresponde ao aprimoramento da qualidade da informação visual para a análise humana (LI et al., 2023). A partir disso, emergem múltiplas técnicas e aperfeiçoamento para o alcance de velocidade, precisão, bem como poder de processamento junto ao baixo custo computacional, cuja aplicação se dá em várias áreas do conhecimento, como engenharia, medicina, artes, entre outras (JOHN e JOSEPH, 2023).

Ruiz et al. (2021) em seu trabalho utilizando técnicas de visão computacional aplicou etapas de pré-processamento em imagens, como a binarização de Otsu 1979, correções de iluminação, técnicas de morfologia e filtros de ruído, para melhorar a qualidade das imagens.

Conforme Rodrigues; Bezerra e Calçada (2023), no sistema de visão computacional é necessário realizar etapas de processamento de imagem a saber: aquisição de imagens, pré-processamento, segmentação, extração de características, reconhecimento e interpretação (Figura 1).

Figura 1. Etapas básicas do processamento de imagens



Fonte: Adaptado de Oliveira Santana et al. (2023).

É importante destacar que o processamento para imagens térmicas abarca várias técnicas, cujos algoritmos para a fase de segmentação são normalmente executados conforme duas propriedades: a similaridade, que corresponde a semelhança entre pixels e um limiar para as regiões de interesse; e a descontinuidade, na qual abarca a divisão da imagem mediante alterações bruscas em sua escala de cores ou intensidade de pixels. Diante disso, constata-se que a segmentação contribui com o reconhecimento de falhas nas imagens por meio do agrupamento ou divisão de pixels junto às características de escala de cinza, cores ou formas semelhantes (CHEN et al., 2023).

Neste contexto, as etapas do processamento de imagens estão descritas, de modo geral, para entendimento das suas peculiaridades no sistema de etapas, que por sua vez são interconectadas (AMARAL e XAVIER, 2023).

1.3.6.1 Aquisição de imagens

Em visão computacional a aquisição de imagem se refere a todo o processo de aquisição dos dados da imagem que se deseja processar, na qual consta desde o registro do alvo com o dispositivo físico até a digitalização dos dados (HUANG et al., 2021). A aquisição de imagens é a primeira etapa de qualquer análise baseada em imagens e pode ser definida como a captura de informações numéricas por meio de câmeras (FERNANDES; DÓREA e ROSA, 2020b).

Quanto aos dispositivos físicos de aquisição de imagens, constatam-se as câmeras que atuam no espectro eletromagnético visível ou no infravermelho, cuja leitura do valor do pixel é correspondente ao nível de energia entendida (THAKUR; VENU e GURUSAMY, 2023). Existem muitos tipos de câmeras, como câmeras CCD, câmeras infravermelhas, câmeras de profundidade etc., disponíveis no mercado; cada tipo de câmera oferece diferentes informações e parâmetros de imagem (ARULMOZHI et al., 2021). Thakur; Venu e Gurusamy (2023) apresentam que os principais meios físicos de obtenção de imagens são as câmeras digitais e os sensores CCD e CMOS.

Tais sensores capturam a luz e convertem em imagem digital (FERNANDES; DÓREA e ROSA, 2020b). Os sensores CCD são carregados com a fonte de luz e as informações capturadas em cada pixel são processadas sequencialmente. Os sensores CMOS, possuem pixels ativos com um transistor para cada pixel para que a informação de cada pixel seja traduzida para a imagem de forma independente e geralmente de forma assíncrona à imagem digital (FERNANDES; DÓREA e ROSA, 2020b). Nas câmeras noturnas, os sensores contam com um emissor, que emite radiação infravermelha no comprimento de onda para iluminar ativamente a cena (LI; MOREAU e IBANEZ-GUZMAN, 2023).

Acerca das premissas conceituais, uma imagem digital é definida como um conjunto de pontos denominados pixels dispostos em uma matriz chamada Bitmap (BMP) ou mapa de Bits, onde cada ponto apresenta uma informação relacionada à cor da imagem, em outras palavras, uma imagem contém uma quantidade discreta de elementos chamados pixels e cada pixel possui um valor (intensidade que varia 0 a 255 tons de cinza) (ROCHISHNA et al., 2023).

O pixel, é estabelecido como o menor elemento de uma imagem digital, na qual constituem uma imagem completa e é identificado pela intensidade do nível de cinza e suas cores correspondentes e após essas intensidades terem sido identificadas, são armazenados em códigos e visualizados em um monitor de vídeo ou impressora, onde 1 byte equivale a 8 bits. As imagens digitais são descritas pelo número de bits para

representar a quantidade de cores possíveis para cada pixel (LI; DELFINO e ZENG, 2023); (MASOUDI et al., 2021).

Nas últimas décadas, as imagens digitais têm desempenhado um papel importante na melhoria do bem-estar dos animais, permitindo a extração de informações por meio de dispositivos como câmeras CCD, que têm a capacidade de capturar imagens coloridas bidimensionais (2D) de objetos, proporcionando uma base para análises detalhadas em estágios subsequentes (ARULMOZHI et al., 2021). Por exemplo, na pesquisa conduzida por Lee et al. (2019) foi examinado o desempenho do crescimento de suínos, empregando aprendizado de máquina utilizando imagens de câmeras de baixo custo.

Marsot et al. (2020) desenvolveram pesquisas usando imagens digitais de 10 suínos de alta qualidade com o objetivo de reconhecer a face dos animais usando redes neurais convolucionais, constataram que o reconhecimento de animais baseado em câmera reduz custos e aumenta a escalabilidade.

Arulmozhi et al. (2021) desenvolveram pesquisas usando imagens digitais para avaliar o comportamento de suínos em ambientes com diferentes sistemas de resfriamentos utilizando modelos computacionais e verificou que diversos trabalhos de pesquisa têm buscado propor sistemas automáticos de visão computacional para execução de tal tarefa utilizando Redes Neurais Convolucionais (RNC), um método promissor que tem sido aplicado em diversas áreas para reconhecimento de padrões de comportamento.

Em relação ao uso de imagens digitais na produção animal, Larsen; Wang e Norton (2021) enfatizam que dados obtidos por meio de imagens podem ser usados para coletar e monitorar as atividades normais de rotina dos suínos e ser útil em avaliações.

Além das imagens coloridas, também tem sido muito utilizadas imagens infravermelhas. As imagens infravermelhas têm sido utilizadas desde a década de 1960 para aplicações militares. A partir dessa década, ocorreram avanços significativos, resultando em imagens térmicas infravermelhas rápidas e precisas, com diversas aplicações em campos diversos (KIRIMTAT et al., 2020).

Messina e Modica (2020) argumentam que tudo se inicia com a captura de uma imagem, a qual se relaciona com a iluminação refletida na superfície dos objetos, aos quais as câmeras térmicas infravermelhas ganharam popularidade devido às melhorias na tecnologia de sensores e à redução de custos.

Câmeras térmicas infravermelhas são sensores calibrados capazes de registrar a radiação emitida na faixa térmica (8–14 μm) e fornece imagens que representam valores de temperatura por pixel (PINEDA; BARÓN e PÉREZ-BUENO, 2020).

Cabe ressaltar que todos os objetos que tenham temperatura acima do zero absoluto (-273°C), emitem radiação infravermelha na sua superfície e, por sua vez são captadas e convertidas em imagens, que podem ser interpretadas por especialistas (EKICI e JAWZAL, 2020; ELMASRY et al., 2020).

Fernandes; Dórea e Rosa (2020b) corroboram esse cenário no campo animal, apresentando que os principais equipamentos físicos utilizados para aquisição de imagens na produção animal são as câmeras digitais padrão ou câmeras de vigilância de ondas eletromagnéticas dentro dos espectros de luz visível para gerar imagens digitais (coloridas ou em tons de cinza) e dispositivos com câmeras infravermelha, ultrassom e radiação ionizante.

Fernandes et al. (2019), utilizaram uma câmera 3D para capturar imagens de suínos e após esses registros as imagens passaram por técnicas de pré-processamento para extração de características.

As imagens térmicas vêm ganhando destaque em vários campos da medicina veterinária e em pesquisas científicas na área (FREITAS et al., 2019). Luximon et al. (2022) enfatizam que tais imagens podem ser estudadas no campo da visão computacional por meio de algoritmos, como entrada de dados para a ciência forense, navegação de robôs, sistemas de gestão de informações, vigilância e aplicações bélicas.

Tal técnica apresenta um grande potencial para analisar conforto térmico animal em ambientes de produção e funciona mapeando um animal, ou parte do corpo deste, distinguindo áreas de diferentes temperaturas por meio da visualização artificial da luz dentro do espectro infravermelho. Além disso, a termografia é em tempo real, não invasivo e não expõe organismos vivos a radiações fortes e prejudiciais como os raios X (ZHENG et al., 2022); (WEIMER et al. (2020).

1.3.6.2 Pré-processamento

A função da etapa de pré-processamento consiste no aprimoramento da qualidade da imagem para as etapas subsequentes. A partir desse panorama, os procedimentos fundamentais empregados nesta etapa, conforme (NARAYAN et al., 2023) são: aplicações de filtros, realces e correções geométricas. Vanzan et al. (2021) relatam que o pré-processamento é um dos passos mais importantes quando se trabalha com imagens. Fernandes et al. (2019) utilizaram técnicas de pré-processamento em imagens de suínos aplicando técnicas de limiarização e binarização para avaliar medidas das costas dos

animais como volume, área, altura e comprimento para previsão do peso corporal em modelos.

a) Aplicação de filtros

Balasamy e Shamia (2023) definem o processo de filtragem como sendo um procedimento para extração de informações como as bordas da imagem ou correção de algumas alterações na imagem, nas quais podem ser, por exemplo: borrões e ruídos introduzidos pelo processo de aquisição ou na transmissão da imagem. Hussain e Khunteta (2020) citam que os ruídos podem ser gerados nas imagens pelo tipo de sensor utilizado, a iluminação do local de aquisição das imagens, as condições climáticas no momento da aquisição da imagem, a posição relativa entre o objeto de interesse e a câmera.

Existem vários tipos de filtros (SHAH et al., 2022), o filtro de média é um filtro linear, isto é, no sentido de suavização de imagens, substituindo cada pixel da imagem pelo valor médio de sua vizinhança, de modo a constatar que quanto maior a ordem da matriz, que por sua vez concebe a máscara, maior será o número de pixels vizinhos considerados no processo, resultando em mais intensidade no que tange ao efeito de suavização (BARELLI, 2019).

Em relação ao filtro de mediana, acontece a substituição do valor de um pixel pela mediana dos valores de intensidade na vizinhança desse pixel. A vizinhança é definida pela dimensão da máscara Mursal e Ibrahim (2020). O filtro de mediana, não é linear e manifesta resultados adequados frente aos demais, quando comparados ao gaussiano para preservar detalhes, bordas ou contornos em imagens (JANA et al., 2023). Neste panorama, ao comparar com os demais filtros mencionados, considera-se o filtro bilateral como o mais indicado quando se trata de suavização da imagem, de tal forma a preservar as particularidades de bordas e contornos (GUPTA et al., 2024). Cabe enfatizar que a convolução desse filtro se mostra similar ao gaussiano. Isso sinaliza que o processo de suavizar se evidencia de forma similar a um filtro linear, porém, modificado e voltado a preservar os detalhes de contorno (BARELLI, 2019).

Os filtros de mediana e bilateral preservam as bordas dos objetos na imagem e, portanto, são os mais importantes para a etapa de extração de contornos, sendo que as imagens processadas pelo filtro bilateral apresentaram maior desempenho (PATHAK e PATIL, 2023).

Outro tipo de filtro, bastante usado é o gaussiano, cujos resultados são considerados adequados no tratamento de imagens com ruído gaussiano, no qual sua aplicação junto a biblioteca OpenCV pode ser alcançada pelo método GaussianBlur (GIEŁCZYK et al., 2022). Seus três parâmetros fundamentais voltados à execução são a imagem a ser tratada; a dimensão da matriz, na qual representa a máscara de filtragem; e o último, o nível de suavização. Entende-se, portanto, quanto maior a dimensão da máscara, maior o efeito do filtro sobre a cena (Barelli, 2019).

b) Realces

Essa etapa busca técnicas da visão computacional capazes de melhorar a imagem a percepção humana. São utilizados vários algoritmos, entre os quais equalização de histograma (ROY; BHALLA e PATEL, 2023).

A equalização de histograma de acordo com Inocêncio et al. (2020), consiste na operação voltada a alcançar uma melhor distribuição dos níveis de cinza da imagem, com base estatísticas, com propósito de correção da iluminação de uma imagem, cuja operação é realizada por meio do uso do histograma da imagem, na qual consiste em uma tabela ou gráfico com as quantidades (frequências) de pixels com os distintos graus de cinza.

PATHAK e PATIL (2023) enfatizam que a equalização de histograma realiza mapeamento da entrada de níveis de cinza para nível de cinza correspondente à sua densidade cumulativa, de modo que a perspectiva de cada nível de cinza da representação resultante seja uniformemente distribuída.

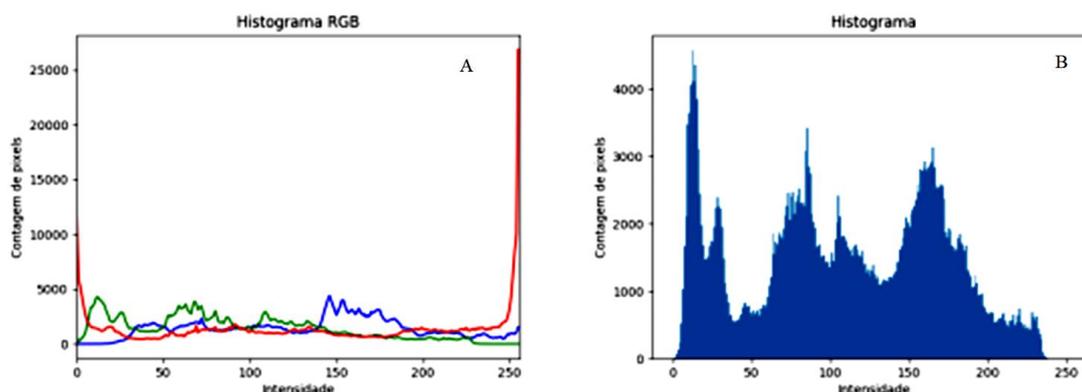
Considera-se que a imagem de saída deve conter a mesma quantidade de pixels para cada valor discreto de nível de cinza. Vale lembrar que a equalização de histograma causa um excessivo realce de contraste, na qual ruídos na imagem podem ser produzidos no processo (SAIFULLAH e DREŹEWSKI, 2023).

Em termos da equalização global, os níveis de cinza em sua totalidade da cena são considerados no processamento, enquanto acontecem apenas nas regiões e fica estabelecida por uma janela para limpar a imagem de forma pontual ou em blocos. Ainda, quando ocorre na regional pontual, somente o ponto central da imagem fica equalizado, já no processo por blocos, isso incide em todos os pontos da janela (MEHDIZADEH et al., 2023).

Dessa forma, Dyke e Hormann (2023) cita que as imagens coloridas possuem 3 canais de cor representando a intensidade necessária da respectiva cor para que quando combinadas resultem na cor do pixel na tela. Imagens em escala de cinza possuem apenas

1 canal, somente uma matriz associada a imagem, sendo a intensidade 0 e 255 correspondentes ao preto e branco. Esses argumentos são representados pelos histogramas, que são gráficos, onde o eixo X representa todas as intensidades (0 a 255), e no eixo Y representa a quantidade de pixels que possuem aquele valor (Figura 2).

Figura 2. Histograma por canal de cor: (A) imagem colorida e de imagem cinza (B).



Fonte: PAES (2017).

Portanto, o histograma consiste numa forma de retratar a distribuição dos números digitais de uma imagem, no qual viabiliza a informação relacionada à proporção da imagem que condiz a cada valor de números digitais (DYKE e HORMANN, 2023).

c) Operações morfológicas

As transformações morfológicas são operações realizadas após a aplicação dos filtros. As operações morfológicas permeiam operações de conjunto, nas quais são estabelecidas para imagens binárias e em seguida desdobradas para representações em tons de cinza e coloridas. Os dois operadores morfológicos básicos são erosão e dilatação, destes dois processos surgem suas variantes, como abertura, fechamento, gradiente etc. Diante disso, dilatação e erosão são consideradas como operações morfológicas básicas, que por sua vez podem definir as demais operações morfológicas (CAMPOS et al., 2023).

A erosão na imagem segundo Lotufo et al. (2023) é como a erosão do solo, ela desgasta os limites do objeto em primeiro plano, baseados na limiarização. O kernel desliza pela imagem como na convolução 2D. Um pixel, na imagem original registrado como 1 ou 0, será considerado 1 apenas se todos os pixels sob o kernel forem 1, caso contrário, ele é corroído, tendo seu valor alterado para 0. Neste processo, todos os pixels próximos ao limite serão descartados, dependendo do tamanho do kernel utilizado. Portanto, a espessura do objeto em primeiro plano na imagem diminui.

A erosão é utilizada para remover pequenos ruídos no objeto, ou seja, o valor dos novos pixels é dado pelo número mínimo de pixels vizinhos dentro da máscara e assim pequenos objetos dentro da máscara são eliminados (LIN et al., 2023).

Kulshreshtha e Nagpal (2023) também destaca que a dilatação é o oposto da erosão. Nela, um elemento de pixel é '1' se pelo menos um pixel sob o kernel for '1'. Portanto, aumenta a região de borda na imagem, isto é, o tamanho do objeto em primeiro plano. É bastante utilizada para unir partes quebradas de um objeto. Ou seja, o valor dos novos pixels é dado pelo número máximo de pixels vizinhos dentro da máscara e assim pequenos buracos dentro da máscara são preenchidos.

Seyedi e Navimipour (2023) corrobora esta informação quando destaca que os operadores fundamentais consistem em erosão e dilatação, os quais são aplicados em uma imagem, de tal forma a utilizar um conjunto de tamanho intitulado elemento estruturante.

Outras operações morfológicas comuns explícitas em Luo et al. (2023) são a abertura e o fechamento, na qual a primeira atenua o contorno da imagem, de tal forma a eliminar contornos agudos, como também propicia a abertura de lacunas na imagem quando ela já sinaliza a presença de pequenas lacunas.

Cabe ressaltar que nas imagens em níveis de cinza, a operação de abertura suprime padrões claros da imagem, menores que o elemento estruturante. Observa-se que a operação dual consiste no fechamento, de modo a remover padrões escuros. Entretanto, essas duas operações podem realizar modificações imensas, de tal forma a ocasionar deformações dos objetos existentes na representação (ZHAO et al., 2023).

Robberecht et al. (2023) informa que mediante o fechamento, ocorre a eliminação de lacunas menores quando comparada ao elemento estruturante, assim como aquelas encontradas no contorno da imagem.

1.3.6.3 Segmentação de imagens

A segmentação é um processo de divisão de uma imagem em regiões de interesse que pode ser um objeto específico a ser detectado na imagem e são definidas com o auxílio de algumas características, como cor, borda ou similaridade (WU e CASTLEMAN, 2023).

Na segmentação uma imagem de entrada é segmentada em regiões de interesse. A segmentação é um processo de separação das imagens em regiões com características estruturais similares, cujas propriedades fundamentais correspondem à amplitude da luminância do pixel, as bordas e texturas. Suas técnicas são responsáveis pela divisão das

imagens em locais de interesse, no sentido de realizar a classificação ou o reconhecimento dos objetos existentes na imagem (ZHANG e ZHANG, 2023).

Neste sentido, é importante salientar que Yuan et al. (2023) revela que esta etapa é complexa para sua implementação, pois, constitui em dividir uma imagem em seus elementos significativos.

Esse processo pode ser efetivado de forma manual ou automática. No tocante à manual, corresponde sobre a imagem os polígonos que retratam regiões homogêneas, enquanto no processo automático, considera-se dados de natureza quantitativa, que por sua vez, observa-se resultados melhores em uma fração de tempo muito menor quando comparados (AIKOH; HOMMA e ABE, 2023).

Conforme Kataras et al. (2023), no início do processo “cada pixel da imagem constitui uma semente e representa um segmento”. Segue-se à inicialização um processo iterativo. A cada iteração, cada segmento é visitado uma única vez seguindo uma ordem pseudoaleatória”, de tal forma a possibilitar um aumento no equilíbrio dos segmentos envolvidos e “a reprodutibilidade dos resultados”.

À vista disso, a segmentação é apontada como uma das tarefas mais complexas no processamento de imagens, uma vez que sua precisão pode estabelecer o êxito ou o fracasso dos processos subsequentes relacionados à análise computadorizada, classificação e reconhecimento de padrões. Seus métodos podem ser classificados como interativos ou automáticos, observando presença ou ausência da intervenção de um humano ao longo do processo (YU et al., 2023); (NARAYAN et al., 2023).

A partir disso, entende-se que não existe um único método de segmentação de imagens e, isso possibilitou o surgimento de diversos algoritmos, tais como: a limiarização, aplicável em imagens com valores de intensidade de pixel, nos quais podem ser congregados em dois ou mais grupos; também a técnica que faz o agrupamento de pixels que apresentem atributos similares, pautada em medidas de características extraídas da imagem (por exemplo, média móvel, desvio padrão); e, ainda, técnicas voltadas à detecção de bordas, apropriado para buscar variações abruptas de intensidade na imagem no sentido de segmentar as regiões (KIM et al., 2023).

a) Detecção de descontinuidades

As descontinuidades relatadas na área de processamento de imagens são pontos, linhas, bordas (limites) de um objeto, ocorridos numa imagem por possuir tons de cinza distintos a região de interesse ou por apresentarem mudanças bruscas de tons de cinza

entre regiões. O principal algoritmo desenvolvido para detectar essas discontinuidades são a segmentação por borda (FU et al., 2023).

Segundo Bennai et al. (2023) tais métodos de detecção de discontinuidades, não resolvem totalmente o problema de uma segmentação, necessitando assim de um pós-processamento, quando geralmente apresentam como resultados falhas de detecção. Portanto, esses métodos devem ser aplicados para reduzir possíveis falhas.

Dentre os métodos de detecção de bordas, o filtro de Canny merece destaque, apresenta dois passos, cuja imagem inicialmente suavizada por meio de um filtro gaussiano, que por sua vez segue com emprego de um filtro derivativo de primeira ordem, como Sobel ou Prewitt, no sentido de destacar regiões da imagem com alto gradiente (CHEN et al., 2023).

Inocência et al. (2020) sinaliza também que o detector de bordas de Canny desenvolvido em 1986 merece ressalva por ser considerada uma das melhores técnicas para se encontrar bordas em uma determinada imagem, nos quais seus resultados procedem do uso de um algoritmo constituído por quatro etapas:

- 1) Aplica-se um filtro Gaussiano (definido pelo usuário) para suavizar a imagem e remover os ruídos, que geram bordas falsas; 2) Encontra-se a intensidade dos gradientes da imagem (aplicando Sobel); 3) Aplica-se a técnica de supressão não máxima para afinar as bordas (mantém apenas o pixel com o maior nível de cinza na largura da borda); 4) Aplica-se uma limiarização dupla (histeresis) para manter os pixels de borda com nível de cinza acima do limiar superior (L_s), eliminar os pixels de borda com nível de cinza abaixo do limiar inferior (L_i) e, analisar os pixels com nível de cinza entre L_i e L_s , mantendo aqueles que possuem vizinhos acima de L_s (para evitar quebras nas linhas de borda) (INOCÊNCIA et al., 2020).

Pode-se ressaltar, também, o filtro de Sobel, cuja aplicação é direcionada para uma suavização no local, além de detectar as alterações de intensidade (bordas), emprega duas máscaras 3×3 , no sentido de estimar os gradientes (variações de tons) na imagem, considerando as *direções vertical* (G_x) e *horizontal* (G_y) (RANJAN e AVASTHI, 2023).

Assim, Inocência et al. (2020) informam que, enquanto o filtro de Sobel apenas realiza a detecção das bordas, o detector de Canny representa um algoritmo mais aprimorado, de tal forma a suavizar, detectar e afinar as bordas, além de impedir interrupções das linhas de borda. Ao passo que possibilita a modificação do grau de suavização e os limiares L_i e L_s , fica passível de alcançar diferentes respostas.

Dentre as técnicas empregadas, observam-se Sobel e GrabCut. No tocante a técnica Sobel, conforme Kong et al. (2023) cada pixel de uma imagem é processado independentemente dos demais dos pixels, nesse sentido se cada pixel presente na imagem pertence ou não à borda. Quanto ao modelo chamado GrabCut, as vantagens consistem na facilidade que existe na interação com o usuário, que por sua vez deve desenhar um retângulo do objeto de análise bem como o algoritmo analisa a segmentação (HARSHAVARDHAN e NALINI, 2023).

Neste contexto, variadas técnicas de segmentação automática são consideradas para diversos estudos, nas quais podem ser divididas, segundo Zhou; Cheng e Tamura (2014) em técnicas automáticas e semiautomáticas, sendo a primeira não necessitar de interferência do usuário para seleção de região ou da área de interesse; enquanto a segunda, de modo geral, começa o processo mediante a seleção, pelo usuário, de um ponto ou local de interesse dentro da imagem.

b) Detecção de Similaridades

A detecção de similaridade considera o interior dos objetos, dispensando as fronteiras que os delimitam e consideram que os pixels que compõe um objeto têm propriedades similares enquanto pixels de objetos distintos têm propriedades distintas. Tais métodos são conhecidos como segmentação por crescimento de regiões, pirâmides, detecção de bacias (WANG et al., 2023)

Tal método, segundo Han et al. (2023) agrupa os pixels das imagens em sub-regiões ou regiões, utilizando limiares de similaridade entre os pixels, baseado em um critério de similaridade fundamentado em um teste de hipótese estatístico e que testa a média entre as regiões similares.

A segmentação por região segue o princípio do funcionamento da técnica de crescimento por regiões e consiste em agrupar pixels ou sub-regiões em regiões maiores (GUO et al., 2023). Seu início se dá com a adoção de um conjunto de pixels “sementes”, a partir das quais é realizado o crescimento das regiões por meio da inclusão, de pixels vizinhos que tenham atributos similares, tais como, intensidade, textura, cor etc. O crescimento ocorre iterativamente até que cada pixel seja processado e sejam formadas diferentes regiões, cujas fronteiras possam ser definidas por polígonos fechados e os pixels internos a essas compartilhem de certa similaridade.

Os métodos de segmentação baseados em região agrupam ou dividem imagens dependendo de seus pixels terem ou não características semelhantes em termos de cor, textura ou formas (QURESHI et al., 2023).

Entre as técnicas de segmentação por atributos, têm-se a segmentação por limiarização. A limiarização ou thresholding é uma das formas de segmentação de uma imagem, onde é separado os grupos de cinza utilizando um limiar, de forma que grupos de pixels com intensidades parecidas sejam separados dos outros, ou seja, é a técnica que separa por meio de um valor de um limiar o objeto do fundo da imagem por meio dos pixels que representam os objetos da frente, dos objetos do fundo da imagem (GHAREHCHOPOGH e IBRIKCI, 2023).

As técnicas de limiarização automatizadas, que mais se destacam são os métodos K-means, de Otsu e o Fuzzy C-means, que estabelecem uma classificação para métodos de segmentação, que por sua vez podem ser baseados em camadas (Layer-based segmentation), utilizados para comparação de conjuntos de imagens, sendo possível realizar a segmentação e métodos baseados em blocos (Block-based segmentation), pautados nos variados atributos encontrados na imagem (HOSNY et al., 2023).

Cabe destacar a limiarização binária que é onde o valor do limiar é fixo e determinado de acordo com a condição visual das etapas anteriores e o método de Otsu de 1975 que calcula o limiar de forma automática para cada imagem (SINGH et al., 2023).

1.3.6.4 Extração de características

A extração de características, para Wan et al. (2023), consiste numa etapa que busca extrair características das imagens que resultaram da etapa anterior (segmentação) que possibilitam definir com precisão cada dígito e que sinalizam boa discriminação entre dígitos parecidos. Cabe destacar que nesta etapa a entrada é uma imagem, entretanto a saída é uma soma de dados proporcionais àquela imagem.

Segundo Wan et al. (2023), o processo de extração de características é possível após a etapa de segmentação e fornece informações para etapas seguintes, como classificação e análise, onde poderão serem consultados o histograma, o tamanho, a área, o perímetro, a textura e contornos etc., dos objetos segmentados na etapa anterior.

Em qualquer sistema de visão computacional, a extração de características de um objeto, em uma determinada imagem, consiste em obter informações capazes de tornar passível a classificação ou identificação de um objeto. Seus atributos podem ser dispostos

em categorias, como características de aspecto, dimensionais, inerciais e topológicas (BARELLI, 2019; YUAN et al., 2023).

Em termos das características de aspecto, o objeto de interesse determina informações acerca da sua coloração ou textura, cujas informações extraídas a respeito da textura podem ter utilidade no sentido de diferenciar objetos (BARELLI, 2019).

Determinadas extrações com uso dessas características relacionadas ao aspecto, conforme Salandra et al. (2023), apresentam-se complexas pela capacidade de estabelecer limitações em função da sinalização de materiais considerados semelhantes. Em geral, a textura contribui para uma melhor exatidão, de forma significativa, no processo de reconhecimento e classificação do objeto.

Em relação à cor, apresentam-se como duas ferramentas eficientes as funções intituladas *Ravel* e *Mode*, na qual a segunda consiste em funções estatísticas capazes de possibilitar a obtenção mais acelerada de alguns componentes, como moda, média e mediana de um *Rol* (BARELLI, 2019).

Quanto às características dimensionais, informações são definidas no que tange ao tamanho do objeto de interesse, cuja área, perímetro e diâmetro são as três principais categorias. Sua área de objeto de interesse se apresenta pelo total de pixels que o representa, na qual essa informação pode ser alcançada através da função *contour* da biblioteca *OpenCV*, que por sua vez requer apenas o objeto segmentado como parâmetro, obtido com a função *findContours* (DHIMAN et al., 2023).

1.3.6.5 Reconhecimento e Interpretação

O reconhecimento e interpretação constituem a última etapa do sistema, no qual o primeiro consiste no processo de atribuição de um rótulo a um objeto pautado em suas características, retratados por seus descritores, enquanto a fase de interpretação abrange atribuir sentido a uma soma de objetos reconhecidos (SEREY et al., 2023).

Um padrão é um objeto detectado na etapa de segmentação e os valores medidos são as características deste padrão. Dessa forma, vários objetos similares, com uma ou mais características em comum, são considerados como pertencente à mesma classe de padrões. As informações que podem ser extraídas dos padrões como particularidades são o contorno, área, volume, altura, largura, textura etc., obtidas por meio de técnicas computacionais específicas (CARDELLICCHIO et al., 2023).

Huang et al. (2023) ressalta que o propósito do reconhecimento de padrões está na identificação de objetos na cena, mediante uma soma de medições no qual cada objeto

corresponde a um padrão e valores mensurados considerados atributos desse padrão. Por sua vez, um composto de objetos similares, com uma ou mais características equivalentes, torna-se caracterizado como pertinente à mesma classe de padrões.

Nesse sentido, caracteriza-se como uma área da ciência pautada na qualificação e classificação de objetos e formas com um determinado número de classes, perante a análise de suas características, cuja aplicação nos sistemas computacionais vem sendo bastante empregado por apresentarem um processamento de objetos, além da análise da informação produzida por este processo (NAUTA et al., 2024).

Um dos métodos utilizado para o reconhecimento e obtenção de um padrão é através da classificação. Nela, é imprescindível ter inicialmente uma boa descrição das classes-padrões, em que se deseja reconhecer e possuir propriedades que não variam à translação, escala e rotação (NAUTA et al., 2024).

Para tanto, o processo abrange três procedimentos fundamentais, que por sua vez são a segmentação do objeto de interesse, a extração de características, a classificação e o resultado. É importante considerar a participação humana como eixo fundamental não apenas no contexto de definição do algoritmo de classificação, mas também para estabelecer as classes, bem como as características definidas no sistema (BARELLI, 2019).

Poongodi; Hamdi e Wang (2023) acreditam que os algoritmos de Aprendizado das Máquinas (AM), se baseiam nas características, previamente extraídas, de um objeto para sua detecção e que essas características são responsáveis para distinguir um objeto do outro, pois as características dos objetos são diferentes umas das outras. Isso, de acordo com Poongodi; Hamdi e Wang (2023) reforça o uso de características em substituição a pixels, pois a velocidade de análise de um objeto por características é bem melhor que por pixels, uma vez que a quantidade de características, naturalmente, tende a ser menor que a quantidade de pixels de uma imagem.

No aprendizado de máquina, os classificadores são uma abordagem de aprendizado supervisionado que é quando é adicionado um rótulo, no qual o programa aprende com a entrada de dados fornecida e, em seguida, usa esse aprendizado para classificar novas observações (WAHEED et al., 2023).

É interessante ressaltar que a descrição das etapas para o processamento não é única e o número dessas etapas também podem variar dependendo do ponto de vista dos autores e dos problemas a qual a visão computacional será aplicada (WAHEED et al., 2023).

Na agropecuária, as técnicas de visão computacional podem ser aplicadas nas múltiplas áreas do conhecimento e em diversas etapas da produção, podendo ser citadas as áreas da agricultura, da agricultura de precisão, da criação de animais de grande e médio porte, da avicultura, do estudo do comportamento animal, entre outras (LIU et al., 2022).

Os sistemas de visão computacional proporcionam inúmeras vantagens comparada aos processos manuais, como a precisão, a confiabilidade e a velocidade na classificação, no entanto, as pesquisas acadêmicas têm sido focadas em pequenos estudos qualitativos, uma vez que encontra dificuldades na investigação dos problemas (CHEN et al., 2023).

O avanço tecnológico possibilitou a utilização da visão computacional para analisar o comportamento por meio de técnicas de visão computacional e estima-se que num futuro próximo, será possível possibilitar a automação de processos no ambiente produtivo, como acionamento de sistemas de climatização, iluminação e manejo sanitário, com ênfase no bem-estar animal, podendo auxiliar os produtores e pesquisadores a resolver problemas de monitoramento de animais, por exemplo, identificação de padrões e sinais comportamentais, pesagem e outras tarefas rotineiras demoradas e onerosas, que podem se tornar mais objetivas, minimizando custos, por meio do processamento de imagens (PANDORFI et al., 2020).

Estudos realizados por Pandorfi et al. (2020) indicaram que no controle do ambiente de produção, são empregados sistemas de identificação comportamental por meio da visão de máquina de imagem 2D e 3D, por serem mais acessível e de menor custo, comparativamente aos sensores relacionados a pecuária de precisão, sendo viável investimento em pesquisas futuras sobre a utilização de técnicas de visão computacional, relacionadas ao desenvolvimento de sistemas completos em tempo real para monitorar os comportamentos dos animais de acordo com sua biologia natural, levando em consideração as mudanças nos parâmetros ambientais, uma vez que fica claro a importância do acesso a informações precisas sobre os comportamentos dos animais, permitindo ao produtor agir rapidamente para resolver problemas ou buscar intervenções. Além disso, o rastreamento automatizado e da frequência de alguns comportamentos anormais, pode facilitar o trabalho de pesquisadores e técnicos da área, que exploram métodos para prevenção ou alívio do problema comportamental.

1.3.7 Redes Neurais Convolucionais - CNN

As Redes neurais convolucionais ou do inglês *Convolutional Neural Networks* (CNNs) são algoritmos de aprendizado profundo que capta uma imagem como entrada, atribui um peso e viés a vários aspectos da imagem para conseguir classificá-las (ZHOU et al., 2023). Elas receberam essa denominação em virtude da operação matemática linear chamada convolução (CHEN et al., 2023).

No trabalho de Krichen (2023) e, Sarvamangala e Kulkarni (2022) uma CNN foi definida como sendo um tipo de rede neural utilizada para o processamento de imagens e são aplicadas em várias áreas do conhecimento.

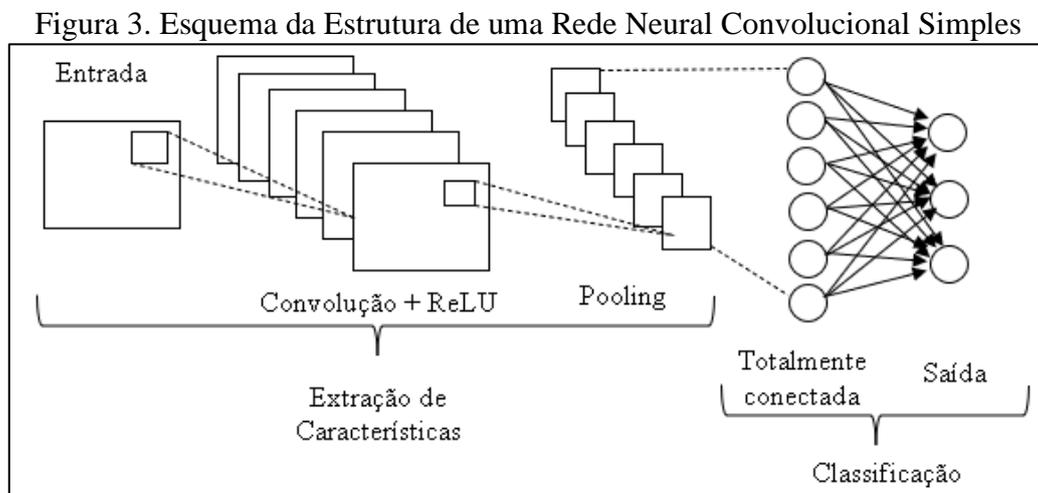
As CNNs são amplamente utilizadas para diversas aplicações, como processamento de imagens, diagnóstico de falhas, reconhecimento de sinais de radar, na área médica, sensoriamento remoto e processamento de linguagem natural, estimativa de pose de animais, diagnóstico de falhas em rolamentos e detecção de alterações em imagens de radar de abertura sintética (SAR) (ZHANG et al., 2023). O uso de CNNs também se estendeu a áreas como controle de congestionamento de tráfego, compensação de desvio de gás e algoritmos de configuração de armazenamento de energia, demonstrando sua versatilidade para enfrentar desafios do mundo real (LONG et al., 2023).

A CNN é uma adaptação das redes neurais artificiais *feedforward* profundas, comumente empregada na análise visual de imagens. Esta arquitetura compreende uma camada de convolução e uma camada de pooling, proporcionando à rede a capacidade de extrair e consolidar características fundamentais das imagens para fins de processamento e interpretação (AARUSHI SHAH et al., 2023).

A primeira camada das CNNs, extrai as características mais simples, como a detecção de bordas. Já na segunda, as características detectadas na primeira seriam usadas para identificar características mais complexas, como cantos e contornos. A terceira poderia identificar formas a partir desses contornos, como por exemplo um círculo. Após extrair essas informações da imagem, a rede utiliza essas características para gerar um conjunto de valores que representam as diversas classes. Quanto maior o valor de uma classe, maior a chance de a imagem ser da respectiva classe de acordo com o modelo (LIU; PU e SUN, 2021).

Gupta; Pathak e Kumar (2022) também mencionaram que a CNN é um sistema complexo composto por diversas camadas, cada uma com uma função específica na

propagação do sinal. Por exemplo, a camada convolucional é responsável pela extração de recursos, enquanto a camada de *pooling* reduz a dimensionalidade dos dados e a camada totalmente conectada conecta todos os neurônios aos das camadas anteriores e subsequentes. A Figura 3 ilustra tais camadas.



Fonte: Adaptado de Gupta; Pathak e Kumar (2022).

De acordo Secchi e Carro (2022) as camadas de entradas são matrizes tridimensionais com altura e largura que variam de acordo com as dimensões da imagem e profundidade, definida pela quantidade de canais de cores.

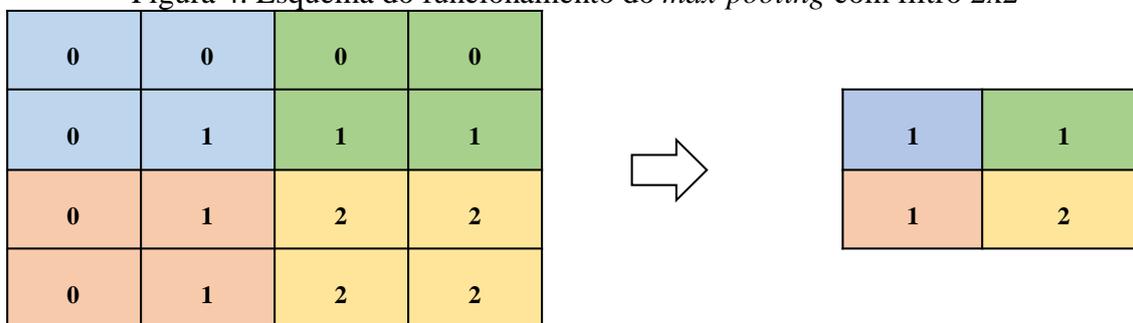
As camadas convolucionais são filtros chamados de *kernel* (DALLA ROSA et al., 2020). Esses filtros extraem os atributos da imagem multiplicando o conjunto de pesos com entrada, onde cada pixel é calculado através de uma média ponderada dos seus pixels vizinhos. Tais filtros são controlados por um parâmetro chamado de *stride* (passo), que é o deslocamento do filtro sobre a imagem (ALBAWI; MOHAMMED e AL-ZAWI, 2017; ANJOS et al., 2021). Após serem calculados pela operação da convolução esses filtros passam por uma camada de ativação, sendo que a mais conhecida é a ReLu (ANJOS et al., 2021) já descrita no subtópico anterior.

As camadas de *pooling* são responsáveis por reduzir a dimensionalidade da imagem após as camadas convolucionais para fazer o processamento, preservando as características da imagem e acelerando o processo da rede (ALBAWI; MOHAMMED e AL-ZAWI, 2017). O *pooling* funciona dividindo a imagem em blocos e pode ser realizado calculando o valor máximo que substitui o valor do pixel pelo maior valor (*max-pool*), as quais recebem o nome de *max-pooling*; calculando o valor mínimo e substituindo pelo pixel de menor valor, sendo chamado de *MinPooling*, ou calculando a média e substituindo pelo valor do pixel, chamando-se *average-pool* ou *average-pooling*,

que substitui pelo valor médio. Dessa forma, segundo Sarki et al. (2022) é diminuído o tamanho dos parâmetros de aprendizado, reduzindo assim o custo computacional.

Em sua pesquisa, Imamura et al. (2021) ilustraram o funcionamento da camada de max-pooling em uma imagem de dimensões 4x4, empregando um filtro 2x2, como demonstrado na Figura 4:

Figura 4. Esquema do funcionamento do *max-pooling* com filtro 2x2



Fonte: Adaptado de Imamura et al. (2021).

As camadas totalmente conectadas são responsáveis por reconhecer o objeto de interesse da imagem. Cada nó dessa camada está conectado ao nó da camada anterior e no da seguinte. Tal camada recebe a saída da camada anterior (*Convolutacional, ReLU* ou *Pooling*) como sua entrada e calcula os valores de probabilidade para classificação nos vários grupos (SARKI et al., 2022).

1.3.7.1 Métricas de Validação das Redes Neurais

Após o treinamento das redes neurais a avaliação do desempenho segundo Dalla Rosa et al. (2020) pode ser verificada por uma matriz de confusão, composta pelo número de Verdadeiros Positivos (VP), Falsos Positivos (FP), Verdadeiros Negativos (VN) e Falsos Negativos (FN), dados pelas classificações feitas pela CNN para problemas binários. Ferreira et al. (2022) citam que na diagonal principal os números representam a quantidade e a porcentagem de dados classificados corretamente e nas demais partes da matriz, os dados classificados erroneamente. Tal matriz de confusão se encontra representada na Figura 5:

Figura 5. Matriz de confusão binária

		Detectada	
		Sim	Não
Real	Sim	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Fonte: Adaptado de Dalla Rosa et al. (2020).

Dessa forma, Dalla Rosa et al. (2020) argumentam que as possibilidades de resultados de classificação são Verdadeiros Positivos (VP) quando ocorre a classificação correta da classe Positivo; Falsos Negativos (FN) (Erro Tipo II): quando o modelo erra, prever a classe Negativo quando o valor real era classe Positivo; Falsos Positivos (FP) (Erro Tipo I): quando o modelo erra, erro em prever a classe Positivo quando o valor real era classe Negativo; e Verdadeiros Negativos (VN): quando o modelo realiza a classificação correta da classe Negativo.

Euis et al. (2021) enfatizam que partir da matriz de confusão pode-se calcular as principais métricas de avaliação de modelos de aprendizado de máquinas, como a acurácia, sensibilidade, especificidade, eficiência, precisão, recall e F1-score.

Para Euis et al. (2021) a acurácia (Eq. 1) é a medida que representa a percentagem de elementos classificados corretamente pelo modelo, indicando uma eficácia geral do modelo. Shedthi; Siddappa e Shetty (2023) enfatizam que esse tipo de avaliação mede o total de predições corretas sob o total de predições. É útil para indicar a eficácia geral do modelo. A desvantagem dessa métrica está em ser eficaz apenas quando há a mesma quantidade de amostras nas diferentes categorias.

$$\text{Acurácia} = \frac{|VP|+|VN|}{|VP|+|VN|+|FP|+|FN|} \quad (1)$$

A sensibilidade mede a fração de eventos verdadeiros detectados (NHU et al., 2020). Avalia a capacidade de detectar resultados positivos, explicando a capacidade do sistema em prever corretamente a condição para casos que realmente a possui e é ilustrado pela Equação 2 a seguir (KOHAVI e PROVOST, 1998):

$$\text{Sensibilidade} = \frac{|VP|}{|VP|+|FP|} \quad (2)$$

A especificidade ao contrário da sensibilidade mede o total de acertos de eventos negativos. Avalia a capacidade de detectar resultados positivos e a especificidade explica

a capacidade do sistema em prever corretamente a ausência da condição para casos que realmente não a possui (ABDELRAHIM et al., 2023). A expressão matemática que expressa a especificidade é ilustrada na Equação 3 a seguir (ABDELRAHIM et al., 2023).

$$\text{Especificidade} = \frac{|VN|}{|VN| + |FP|} \quad (3)$$

Freitas et al. (2019) recomendam após calcular a sensibilidade e a especificidade, calcular a eficiência por meio da sua média aritmética explícita na Equação 4 a seguir para evitar erros de sensibilidade das acurácias.

$$\text{Eficiencia} = \frac{\text{Sensibilidade} + \text{Especificidade}}{2} \quad (4)$$

Para Dalla Rosa et al. (2020) a precisão é a quantidade de segmentos que, dentre todos os segmentos classificados como positivos, são pertencem a classe positiva (DALLA et al., 2020). Tal métrica se encontra explícita na Equação 5 (DALLA ROSA et al., 2020).

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (5)$$

Conforme Yusof et al. (2019) o Recall ou Revocação é a quantidade de segmentos positivos que foram classificados corretamente (YUSOF et al., 2019). O recall pode ser avaliado de acordo com a Equação 6:

$$\text{Recall} = \frac{VP}{VP + FN} \quad (6)$$

Para Irmak et al. (2023) a métrica F1-score considera tanto a taxa de precisão quanto o recall. O seu valor tradicional é a média harmônica entre a precisão e o recall multiplicado pela constante 2. A expressão matemática que expressa. O F1-score é apresentada na Equação 7 a seguir (IRMAK et al., 2023):

$$F1 = 2 \times \frac{\text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (7)$$

Ajayi e Ashi (2023) citam que para avaliar o desempenho de modelos de classificação de duas classes, todas as métricas de desempenho podem ser aplicadas.

Porém de acordo com Heydarian; Doyle e Samavi (2022) para problemas de mais de duas classes, é recomendado o uso da matriz de confusão multiclasse. Li; Sun e Li (2023) indicam que a matriz de confusão é construída comparando a classe predita com a classe conhecida.

Em problemas de classificação multiclasse cada instância de dados é atribuída a uma única classe distinta, sendo, portanto, a matriz de confusão uma apresentação útil e abrangente do desempenho do classificador em um conjunto de dados supervisionados (KRSTINIĆ; ŠERIC e SLAPNIČAR, 2023). Grandini; Bagli e Visani (2020) indicam que na matriz de confusão multiclasse, as linhas trazem os valores verdadeiros e as colunas apresentam os valores previstos e na diagonal principal são apresentados os elementos classificados corretamente, enquanto os elementos fora da diagonal principal representam erros de classificação, semelhante a matriz de confusão para problemas de classe binária.

Na Figura 6, as classes (representadas pelas letras a, b, c e d) preditas corretamente estão expressas na diagonal principal em cores verdes e em cores brancas as classes preditas erroneamente (GRANDINI; BAGLI e VISANI, 2020).

Figura 6. Representação de matriz de confusão multi classe.

		Classificação Prevista				Total
		Classes	a	b	c	
Classificação atual	a					
	b					
	c					
	d					
	Total					

Fonte: Adaptado de Grandini; Bagli e Visani (2020).

A precisão para cada classe é calculada dividindo um elemento diagonal principal da matriz de confusão com a soma de todos os elementos na coluna correspondente. A métrica é calculada para cada classe, tratando-a como um problema de classificação binária após agrupar todas as outras classes como pertencentes à segunda classe (KRSTINIĆ; ŠERIC e SLAPNIČAR, 2023).

Markoulidakis et al. (2022) citam que decorrente da matriz de confusão multiclasse as métricas de desempenho utilizadas são a acurácia, Recall ou revogação, Precisão e F1-Score.

1.3.8 Algoritmo YOLO (*You Only Look Once*)

O termo YOLO é derivado da expressão em inglês *You Only Look Once*, em português, significa você olha apenas uma vez e é um método baseado em Redes Neurais Convolucionais que realiza detecção de objetos com o método de passada única (SÁ e FIGUEIREDO, 2022a). Li; Pan e Li (2023) citam que o YOLOv5 é um algoritmo de detecção de alvo de um estágio proposto em 2020. Tal método prioriza o tempo de resposta de inferência. Ele realiza inferência em um intervalo de tempo curto, mantendo uma acurácia alta (LI et al., 2020).

As etapas fundamentais da detecção de objetos consistem principalmente na identificação da área e na classificação da categoria. O algoritmo YOLOv5 mescla essas duas etapas em um único processo, diferente de outros detectores que realiza as tarefas em etapas separadas (ZHANG e WEN, 2022). Segundo Lei; Tang e Li (2022), o algoritmo YOLO possui versões que tem como finalidade substituir o algoritmo de dois estágios de ROI (Região de Interesse) e detecção de alvo por um conjunto de algoritmos de um estágio da rede para tratar a tarefa de detecção de objetos como um problema de regressão; sendo que a posição da caixa delimitadora e a categoria à qual ela pertence são retornadas diretamente à camada de saída. Zhang et al. (2023) complementam que a técnica de YOLOv5 para detecção de objetos é realizada em um único estágio, diretamente na imagem de entrada e por isso apresenta um tempo de execução mais rápido do que a detecção de objetos em dois estágios.

O YOLOv5 é um detector de objetos em tempo real de estágio único de última geração baseado nos modelos YOLOv1, YOLOv2, YOLOv3 e YOLOv4, ao qual os desenvolvimentos contínuos resultaram em desempenhos superiores em dois conjuntos de dados oficiais (AHMAD et al., 2022). Tal modelo obteve resultados superiores nas classes de objetos visuais pascal (VOC) e no conjunto de dados objetos da Microsoft em contexto (COCO) (DEXTRE et al., 2021).

O modelo YOLOv5, desenvolvido pela Ultralytics, foi reconhecido como um algoritmo para detecção de objetos no processamento de imagens. O modelo tem sido amplamente aplicado em vários domínios, incluindo agricultura, saúde, infraestrutura e monitoramento ambiental (STEFENON et al., 2023).

O modelo foi ampliado e aprimorado para enfrentar desafios específicos em diferentes domínios, como segmentação de instâncias para frutas, detecção de máscaras faciais para combater a COVID-19 e detecção de fraturas de costelas em imagens médicas (AARON et al., 2023; XU et al., 2023; TSAI et al., 2023). Além disso, o YOLOv5 tem sido utilizado para detectar detritos de objetos estranhos, localização de tumores cerebrais e identificar áreas de construção perigosas, mostrando sua versatilidade e aplicabilidade em diferentes campos (JAMES et al., 2023; SONG et al., 2023; YANG, 2023).

O modelo YOLOv5 oferece várias versões, incluindo YOLOv5s, YOLOv5m, YOLOv5l, YOLOv5x e YOLOv5n, cada uma adaptada a requisitos e restrições específicas (SOUZA et al., 2023). Essas versões permitem flexibilidade no controle do tamanho do modelo e na otimização do desempenho para diferentes casos de uso. Além disso, o modelo YOLOv5 foi aprimorado por meio da integração de cabeçote desacoplado de ativação adaptativa para detecção de lixo, funções de perda aprimoradas e arquiteturas leves, demonstrando esforços contínuos para refinar suas capacidades (DONG et al., 2023).

O modelo YOLOv5 emergiu como uma ferramenta versátil e poderosa para detecção de objetos, oferecendo robustez, velocidade e adaptabilidade o tornam um ativo valioso para aplicações que exigem detecção precisa e em tempo real de objetos (LI et al., 2023).

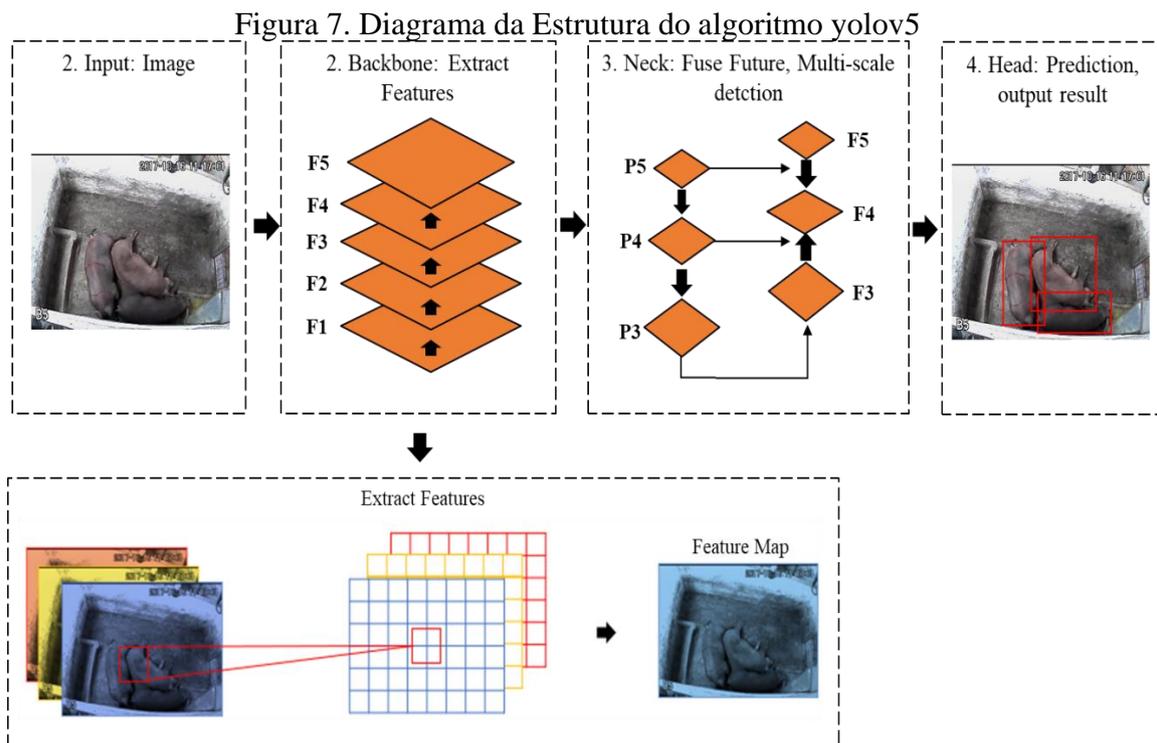
1.3.8.1 Estrutura do Yolov5

O YOLOv5 é dividido em quatro variantes de modelo de rede com base em sua profundidade e largura: YOLOv5s (pequeno), YOLOv5m (médio), YOLOv5l (grande), e YOLOv5x (extremo). Dai et al. (2022) enfatizam que a complexidade de suas redes diminui em ordem. Xiong et al. (2022) relatam que partindo de s até x, aumenta-se o nível de precisão da rede e por consequência, a capacidade de processamento necessária e que tais modelos podem ser selecionados pelo usuário e avaliado o melhor para o conjunto de dados. Yang et al. (2023) citam que a estrutura dos quatro modelos em escala é a mesma, apenas ocorre a redução do tamanho e da complexidade. Enquanto a rede YOLOv5x exibe a maior precisão média, ela também possui a velocidade de computação mais lenta. Por outro lado, a rede YOLOv5s é amplamente empregada em dispositivos leves devido à sua eficiência (CHEN et al., 2023).

O modelo YOLOv5 é flexível, leve e mais rápido que outros detectores ou classificadores e é dividido em 4 (quatro) partes: tronco (*backbone*), pescoço (*neck*) e

cabeça (*head*) ou saída (LEI; TANG e LI, 2022). Li; Pan e Li (2023) apontam que tais partes são conectadas e tal estrutura simula um organismo vivo, onde o tronco sustenta o pescoço e este sustenta a cabeça.

De acordo com WANG et al. (2019) o tronco ou *backbone* do YOLOv5 extrai as principais características da imagem de entrada. Realiza o particionamento do mapa de características da imagem e em seguida os funde. Isso faz com que o gradiente se propague por diferentes caminhos da rede e aprimora a estrutura de *pooling* para extrair as informações de recursos das imagens, diminuindo assim o custo computacional durante a extração do mapa de características e com isso possibilita uma maior velocidade de inferência. A camada intermediária do YOLOv5, o pescoço ou *neck*, é basicamente responsável por gerar as pirâmides de características. Nessa parte, é identificado o objeto em diferentes tamanhos e escalas (SUN et al., 2023). Na camada da cabeça ou *head* do YOLOv5 acontece a detecção dos objetos nas imagens. Nela são formadas as bounding boxes e as probabilidades de acerto da detecção. O YOLOv5 gera três tamanhos diferentes (18×18 , 36×36 , 72×72) de mapas de características para obter previsão em várias escalas, permitindo que o modelo lide com objetos pequenos, médios e grandes (XU et al., 2021). A Figura 7, ilustra o diagrama da estrutura do YOLOv5.



Fonte: Adaptado de Haohui et al. (2022).

Conforme observado na Figura 7, as imagens passam primeiro na camada de entrada, onde são submetidas a processos de aprimoramento de dados em mosaico e âncoras de caixa delimitadora de aprendizado automático. Em seguida as imagens são encaminhadas para a camada espinha dorsal (*backbone*), que é a rede de extração de características (F1, F2, F3, F4, F5) (ZHANG et al., 2022). Nessa camada são empregadas técnicas de redução de amostragem de foco, estrutura melhorada de cross stage parcial (CSP) e estrutura de agrupamento de pirâmide espacial (SPP) para extrair as informações de recursos das imagens (LI; PAN e LI, 2023). Na camada do pescoço (*neck*) ocorre a “tática de torre dupla” do YOLOv5, ou seja, a rede de agregação de caminhos (PAN), onde quatro mapas de características são extraídos e depois mesclados em saídas de características tridimensionais através da terceira camada, Pescoço (Neck). A camada Neck usa a rede Path Aggregation Network (PANet). Para uma informação de características mais abrangente, as três camadas de características de fusão de entrada são empilhadas através do *upsampling* e *downsampling* passo a passo do PANet. Uma segunda fusão é realizada para obter três camadas de características eficazes, nomeadamente, P1, P2 e P3, como mostrado na Figura 7. Desta forma, o Neck contém tanto a informação de localização, quanto a semântica de classificação (LI et al., 2022).

Posteriormente, a camada de predição (*cabeca-head*) elabora as informações de predição das imagens (ou seja, informações de coordenadas das caixas delimitadoras, confiança da predição e classes de um objeto). É uma rede de agregação de caminhos que utiliza a rede (PANet) usada para realizar uma fusão secundária das três características de fusão com informações de localização subjacentes. Em seguida, as três características de fusão em diferentes escalas são divididas em grades para prever a caixa delimitadora para cada grade e depois retornar à caixa de verdade básica. Cada mapa de características de escala armazena as categorias de classes, parâmetros de regressão das caixas anteriores (localização) e pontuações de confiança que correspondem às três caixas anteriores de cada grade (ZHANG et al., 2023).

Degaki et al. (2022) descrevem que o aprimoramento de dados do mosaico da camada de entrada serve para enriquecer o plano de fundo da imagem e o número de pequenos objetos no conjunto de dados combinando quatro imagens. O redimensionamento do tamanho de imagem adiciona bordas pretas mínimas às imagens originais de diferentes comprimentos e larguras e as dimensiona uniformemente para um tamanho padrão.

O cálculo adaptativo da caixa âncora da camada de entrada compara as caixas previstas de saída com as caixas reais com base nas caixas âncora iniciais, calcula o intervalo e, em seguida, atualiza-o ao contrário, iterando continuamente os parâmetros para obter o valor da caixa âncora mais adequado (DEGAKI et al., 2022). Para lidar com objetos sobrepostos, o YOLO adota diferentes tamanhos de caixas âncoras. Em essência, cada caixa âncora é usada para calcular a sobreposição dividida pela não sobreposição com as caixas delimitadoras dos objetos presentes na imagem (DEGAKI et al., 2022).

Durante o processo de treinamento, a caixa delimitadora prevista pelo modelo é comparada iterativamente com a caixa delimitadora verdadeira para obter o retângulo delimitador mais adequado para cada objeto detectado (CHANG e ZHANG, 2022).

Yousry e Khattab (2022) enfatizam que as âncoras são retângulos com razões entre largura e altura pré-definidos para representar objetos com tamanhos fixos. Em caso de objetos com tamanhos variados, tais âncoras não os representam (XU et al., 2021). Para resolver esse problema o YOLOv5 utiliza uma função a qual faz uso das marcações das imagens de treinamento para a geração de âncoras adaptadas para os objetos de tamanhos diferentes (JUNLONG et al., 2021).

O aprimoramento de dados em mosaico, foi proposto pelo desenvolvedor do algoritmo YOLOv5, Glenn Jocher, como contribuição para o repositório original da YOLO, a qual utiliza a seleção de hiperparâmetros através de algoritmo genético (BOCHKOVSKIY et al., 2020).

O dimensionamento adaptável de imagem funciona para conjunto de dados onde as imagens não possuem o mesmo tamanho, comprimentos e larguras iguais, e assim o YOLOv5 as redimensiona sem causar distorções, padronizando o tamanho das imagens (ZHANG et al., 2021).

Na camada de saída são realizadas as predições das bounding boxes utilizando a função de perda GIoU e a Supressão de não máximos. Tong et al. (2022) exemplificam que a supressão não máxima significa que várias caixas candidatas são obtidas pelo classificador e o valor de probabilidade das caixas candidatas pertencentes à categoria é classificado de acordo com a probabilidade de classificação da categoria obtida pelo classificador. As caixas, cujo valor de probabilidade excede o valor limite, são descartadas e as caixas restantes, selecionadas com a pontuação mais alta. Porém, o YOLOv5 utiliza uma variação do IoU chamada de GIoU, *Generalized Intersection over Union* expressa pela Equação 8 (SANTOS, 2022).

$$GIoU = \frac{|A \cap B|}{|A \cup B|} - \frac{|C(A \cup B)|}{|C|} = IoU - \frac{|C(A \cup B)|}{|C|} \quad (8)$$

em que, A e B são duas caixas delimitadoras e C é o menor retângulo que pode conter A e B. O valor do GIoU, por sua vez varia entre -1 e 1.

Khan et al. (2020) citam que dentre as técnicas de visão computacional usando rede neural, a ferramenta YOLO (You Only Look Once) para detecção de objetos, é a mais rápida de treinar e mais eficiente, além disso, pode ser implementada usando a nuvem do Google com uma GPU gratuita. Para resolver problemas com o tamanho da imagem Nepal e Eslamiat (2022a) reduziram os seus tamanhos.

O avanço significativo da tecnologia no campo de aprendizado de máquina, têm possibilitado a atualização de algoritmos, a saber o YOLOv5 e o FCN e sabendo das vantagens e desvantagens do algoritmo YOLO, o algoritmo YOLOv5 é estabelecido para melhorar o efeito de detecção ruim de alvos pequenos e também faz com que o referido algoritmo mostre alta adaptabilidade a imagens de diferentes tamanhos, sendo que possui uma taxa de chamada para esses fins e quando a mesma é inferior a 0,8, a precisão de detecção do algoritmo pode basicamente se manter entre 1,0 e 1,2 (WU et al., 2021).

1.3.8.2 Hiperparâmetros do YOLOv5

O treinamento das Redes Neurais Convolucionais (CNN) requer o ajuste de hiperparâmetros (PINA et al. 2019). Segundo Agrawal e Chakraborty (2021) os hiperparâmetros são parâmetros definidos com base nos dados que são fornecidos ao modelo e à capacidade de o algoritmo, para maximizar sua aprendizagem. Para Nematzadeh et al. (2022) o ajuste desses hiperparâmetros em um modelo eficiente é um dos aspectos mais importantes. Conforme Costa, Figueroa e Fracarolli (2020) os hiperparâmetros podem alterar o resultado de um modelo, por isso a importância de serem escolhidos corretamente. Sarki et al. (2020) recomendam modificar os hiperparâmetros para aumentar a eficiência de algoritmos de aprendizado de máquina.

O processo de encontrar a combinação ideal de hiperparâmetros do modelo é chamado de otimização de hiperparâmetros e muita das vezes esse processo é feito de forma manual, por tentativa e erro, ou baseado em experiências anteriores, podendo gerar erros (VICTORIA e MARAGATHAM, 2021). Na tentativa de otimizar a busca pela otimização dos hiperparâmetros foram desenvolvidos vários métodos. Os principais são:

busca em grade (Grid Search), busca aleatória (Random Search) e algoritmos genéticos (*Genetic Algorithms*) (ALIBRAHIM e LUDWIG, 2021).

A busca em grade, ou Grid Search, baseia-se na busca exaustiva pelo conjunto de combinações dos hiperparâmetros (espaço de busca) passado pelo usuário, percorrendo todas as possibilidades de hiperparâmetros, onde a cada iteração um elemento desse conjunto é escolhido para dar origem a um novo modelo e apresentando no final a configuração do modelo de melhor desempenho, demandando assim um custo computacional alto, tornando esse método de otimização hiperparâométrica caro em termos de tempo de execução (ZHENG et al., 2021). No trabalho de Queiroga et al. (2020) o método *gridsearch*, utiliza uma lista de valores para cada parâmetro como a entrada da busca. Assim, o algoritmo testa todas as combinações possíveis naquela lista e retorna a que obteve o melhor resultado.

A técnica busca aleatória *Random Search*, ao contrário da anterior não percorre todo o conjunto de combinações de hiperparâmetros, mas apenas uma faixa de valores onde estão os possíveis hiperparâmetros (COSTA; FIGUEROA e FRACAROLLI, 2020). Queiroga et al. (2020) descreveram que o método Random Search, também utiliza uma lista com valores de hiperparâmetros como entrada de forma conjunta ao número de testes, assim as combinações dessa lista são testadas de forma randômica.

O algoritmo genético é um algoritmo evolutivo que vem sendo utilizado em vários campos de pesquisa como um otimizador útil e eficaz na resolução de problemas (VENTURA et al., 2022). Tais algoritmos são de busca inteligentes e podem ser comparados com fenômenos que ocorrem na evolução biológica, como cruzamento e mutação, inspirados no princípio Darwiniano.

No trabalho de Periaux e Tuovinen (2023), o algoritmo genético, é baseado no princípio da seleção natural proposto por Charles Darwin (sobrevivência do mais apto e eliminação do inferior) para encontrar o ponto de ótimo global das redes neurais. Segundo Elgeldawi et al. (2021) ele consiste em um conjunto definido de hiperparâmetros criados que, a cada geração, é avaliado por uma função objetiva, e os melhores são selecionados, ou seja, esse algoritmo encontra soluções cada vez melhores a partir da evolução das gerações anteriores.

Liashchynskiy e Liashchynskiy (2019) fizeram um estudo comparativo entre esses três métodos avaliando o tempo entre as três técnicas de otimização que levou para encontrar o melhor modelo e a acurácia do modelo e constataram que o *random search* levou 2,7 horas, enquanto o *grid search* 4,3 horas e o algoritmo genético levou 4,13 horas

para executar e em relação a acurácia o método *grid search* obteve 83% e o o algoritmo genético 86%. No entanto, Queiroga et al. (2020) cita que esse tempo no algoritmo genético pode ser controlado pelo número de gerações. Essa técnica conforme Bochkovskiy; Wang e Liao (2020) utiliza seleção de hiperparâmetros através de algoritmo genético para resolver os problemas de detecção.

De acordo com Jocher et al. (2020) o YOLOv5 possui cerca de 30 hiperparâmetros usados para realizar várias configurações no treinamento e foram definidos para treinar o conjunto de dados COCO. Os hiperparâmetros do YOLOv5 e o espaço de busca foram definidos por Jocher et al. (2020), expressos na Tabela 4.

Tabela 4. Hiperparâmetros e espaço de busca do YOLOv5

Hiperparâmetros	Espaço de busca
Taxa de aprendizado inicial - lr0	(1, 1e-5, 1e-1)
Taxa de aprendizado final - lrf	(1, 0.01, 1.0)
Momentum	(0.3, 0.6, 0.98)
Decaimento do peso otimizador – weight decay	(1, 0.0, 0.001)
Épocas de aquecimento – warmup epochs	(1, 0.0, 5.0)
Momento inicial de aquecimento - warmup_momentum	(1, 0.0, 0.95)
Aquecimento inicial bias - warmup_bias_lr	(1, 0.0, 0.2)
Ganho de Perda de caixa - box	(1, 0.02, 0.2)
Ganho de perda de classificação - cls	(1, 0.2, 4.0)
Perda de classificação - cls_pw	(1, 0.5, 2.0)
Ganho de perda de objetividade - obj	(1, 0.2, 4.0)
Peso positivo - obj_pw	(1, 0.5, 2.0)
Limite de treinamento - iou_t	(0, 0.1, 0.7)
Limite de múltiplas âncoras - anchor_t	(1, 2.0, 8.0)
Âncoras por grade de saída - anchors	(2, 2.0, 10.0)
Perda focal - fl_gamma	(0, 0.0, 2.0)
Aumento de imagem - hsv_h	(1, 0.0, 0.1)
Aumento de saturação HSV da imagem - hsv_s	(1, 0.0, 0.9)
Aumento de valor HSV da imagem - hsv_v	(1, 0.0, 0.9)
Rotação da imagem - degrees	(1, 0.0, 45.0)
Tradução da imagem - translate	(1, 0.0, 0.9)
Escala da Imagem - scale	(1, 0.0, 0.9)
Cisalhamento da imagem - shear	(1, 0.0, 10.0)
Perspectiva da imagem - perspective	(0, 0.0, 0.001)
Rotaciona a imagem de cima para baixo - flipud	(1, 0.0, 1.0)
Rotaciona a imagem da esquerda para direita - fliplr	(0, 0.0, 1.0)
Mistura de imagens - mosaic	(1, 0.0, 1.0)
Mistura de imagem - mixup	(1, 0.0, 1.0)
Segmento copiar colar – copy paste	(1, 0.0, 1.0)

Fonte: Jocher et al. (2020).

Dessa forma, Jocher et al. (2020) acrescenta que os hiperparâmetros do YOLOv5 podem ser otimizados usando o modelo de algoritmo genético para banco de dados personalizados por meio do espaço de busca. Koch et al. (2018) relataram que os hiperparâmetros ideais para um modelo podem variar de acordo com os dados e por isso é importante a modificação para cada conjunto de dados.

A taxa de aprendizado segundo Zheng; Liu e Yin (2021) se refere a medida da rapidez com que o vetor de pesos será atualizado, ou seja, descreve o quão rápido a rede irá se aproximar da solução. Arafin; Issa e Billah (2022) descrevem também que a taxa de aprendizado determina o tamanho dos passos para atingir um mínimo local. Esse parâmetro é importante definir, pois, uma taxa de aprendizado muito baixa, torna o aprendizado do algoritmo muito lento e ele alto demais provoca instabilidade na rede. Para isso, são utilizados otimizadores de treinamento que adapta a taxa de aprendizado aos dados. Arafin; Issa e Billah (2022) citam que o YOLOv5 como padrão é treinado com o otimizador gradiente descendente estocástico (SGD).

O termo *mometum* é uma técnica utilizada para acelerar o processo de treinamento e reduzir a incidência de mínimos locais, que são pontos na superfície de erro que apresentam uma solução estável, porém, não a saída correta das predições (BRAGA et al., 2007). Sendo assim, esse parâmetro é importante ser definido, pois acelera o processo de treinamento e reduz o perigo de instabilidade da rede.

Os hiperparâmetros de aquecimento (épocas de aquecimento, momento inicial de aquecimento e aquecimento inicial bias) segundo Dai; Hu e Fan (2022) são usados para garantir que o modelo comece a treinar com um certo conhecimento prévio dos dados.

Os hiperparâmetros de perda do modelo YOLOv5 (perda de caixa, perda de objetividade e perda de classificação) segundo Kasper-Eulaers et al. (2021) são indicadores do algoritmo: a perda de caixa representa quão bem o algoritmo pode localizar o centro de um objeto e quão bem a caixa delimitadora prevista cobre um objeto. A objetividade é essencialmente uma medida da probabilidade de que um objeto exista em uma região de interesse proposta. Se a objetividade for alta, isso significa que a janela de imagem provavelmente contém um objeto.

A perda de classificação dá uma ideia de quão bem o algoritmo pode prever a classe correta de um determinado objeto. Seus resultados significam que as classes usadas para detecção são reconhecidas com precisão durante o processo de treinamento (JUNG e CHOI, 2021).

A perda focal segundo Wang et al. (2022) é uma função de perda baseada na entropia cruzada binária. É uma função de perda de entropia cruzada de escala dinâmica que pode reduzir o peso de amostras facilmente distinguíveis no treinamento. O método pode ajudar a rede a se concentrar rapidamente em amostras difíceis, tanto positivas quanto negativas, que são úteis para a rede de treinamento (YAOSHUN; LI e LIU, 2021). O YOLOv5 utiliza a função de perda focal para substituir a função de perda de entropia cruzada e para reduzir a taxa de problemas relacionados com o desequilíbrio das amostras positivas e negativas e amostras difíceis e fáceis e a função de perda focal é otimizada pelo cálculo dinâmico do fator de peso (YAOSHUN; LI e LIU, 2021).

A resolução da imagem para o YOLOv5 é a que melhor equaliza a quantidade de informação de todas as imagens da base de dados e em relação ao aumento de dados o giro (*Flip*) gera o espelhamento das imagens da base de dados; e a rotação das imagens rotaciona-se em ângulos e sentidos aleatórios dentro de um limite estabelecido pelo espaço de busca (ZHANG et al., 2022).

O parâmetro de intervalo de escala (*Scale*) segundo Dai; Hu e Fan (2022) é aplicado para realizar transformações de escala aleatórias, podendo expandir a imagem. Mohiyuddin et al. (2022) enfatiza que a escala realiza a modificação da escala das imagens a com a função de gerar novas características nas imagens existentes na base de dados.

A técnica de cisalhamento da imagem (*Shear*) proposta como hiperparâmetros do YOLOv5 fixa um eixo da imagem e depois estica o outro eixo para um ângulo específico do espaço de busca, chamado de ângulo de cisalhamento (DAI; HU e FAN, 2022).

Em relação as técnicas de mistura de imagem aplicadas no YOLO, segundo Zhou (2022a), o mosaico tem a função de unir quatro imagens em uma imagem só, gerando novas imagens e isso pode mostrar mais detecção de objetos de destino, acelerar o efeito de treinamento do modelo e melhorar a generalização do modelo. Tal aprimoramento em mosaico, enriquece o conjunto de dados (ADIBHATLA et al., 2021).

O modelo YOLO é descrito por Anwar Shah et al. (2022) como sendo um método de aprendizado profundo eficiente, supera o modelo R-CNN e todas as suas variantes, detectando objetos, por meio da visualização de uma imagem de uma forma muito eficiente, sendo extremamente rápido e direto em comparação com outros modelos de detecção de objetos, possibilitando a divisão da imagem em grade de células, uma vez que cada uma dessas células prevê o número de caixas delimitadoras e pontuações de confiança, que informa se a forma da caixa é um pouco diferente das demais.

1.3.8.3 Métricas de avaliação do YOLOv5

No trabalho de Gui et al. (2023) foram empregadas as métricas de AP (Precisão Média), P (Precisão) e R (Revocação) para avaliar o desempenho do modelo na detecção dos botões de chá. Os autores complementam que a AP é a principal métrica para avaliar o desempenho de um modelo de detecção.

Na pesquisa de Li; Sun e Li (2023) as métricas utilizadas foram a precisão média, precisão, recall, F1-score e o número de quadros por segundo (FPS) para avaliar a velocidade de detecção do modelo, descrevendo que AP é a precisão média de uma única categoria de destino, enquanto mAP é a precisão média de todas as categorias.

O mAP é uma métrica que se baseia na área sob a curva de precisão e recall (PRC) e é pré-processada para eliminar o comportamento em zigue-zague (PADILLA et al., 2021). Dessa forma, no caso de um desequilíbrio de classes, onde há um maior número de instâncias de uma classe em relação à outra, o mAP se torna uma métrica mais confiável e poderosa para analisar o desempenho de um classificador (PADILLA et al., 2021).

Segundo Meng et al. (2023a) a métrica mAP (mean Average Precision) é amplamente utilizada para avaliar o desempenho de algoritmos de detecção de objetos. Essa métrica calcula a área média sob a curva Precision-Recall, o que proporciona uma avaliação completa da precisão de localização e do reconhecimento do classificador. Em suma, o mAP é uma medida que permite mensurar a eficácia geral do algoritmo na tarefa de detecção de objetos (Eq. 9 e 10).

$$AP = \sum_n (R_n - R_{n-1}) \cdot P_n \quad (9)$$

$$mAP = \frac{1}{N} * \sum_{t=1}^N AP_t \quad (10)$$

Nesse contexto, Padilla et al. (2021) argumentam que o Recall é a proporção de verdadeiros positivos em relação a todas as instâncias positivas (eq. 9); P_n representa a precisão máxima naquele Recall, e N indica o número de classes consideradas no problema de classificação.

Ainda no trabalho de Meng et al. (2023a) foi utilizado a métrica GFLOPs, que é uma métrica que mede a complexidade computacional ou eficiência do modelo. Indica a

quantidade de operações de ponto flutuante que o modelo pode executar por segundo, o que está relacionado à velocidade de processamento do modelo computacional.

Lawal; Zhu e Cheng (2023) para avaliar o desempenho do YOLOv5 na detecção de frutas utilizaram as métricas precisão (Eq. 5), recall (Eq. 6), F1-score (Eq. 7), precisão média (Eq. 9), precisão média média (Eq. 10), velocidade de processamento (Eq. 11), número de camadas, quantidade de parâmetros (params) (Eq. 12), GLOPs (Eq. 13) e tamanho do peso do modelo.

$$Velocidade = \frac{Quadros}{Tempo} \quad (11)$$

$$Parâmetros = [i * (k * k) * o] + o \quad (12)$$

$$GLOPs = Parâmetros H * W \quad (13)$$

No trabalho de Wang et al. (2023) foram utilizadas várias métricas para avaliar o desempenho do algoritmo na detecção de frutas de tomate. Entre as métricas adotadas, destacam-se a precisão, a revogação e o F1 Score. Além disso, a métrica mAP também foi empregada. Outra métrica relevante empregada nesse estudo é o IoU (Intersection over Union), que mede a sobreposição entre as caixas delimitadoras preditas pelo modelo e as caixas delimitadoras verdadeiras. O IoU é utilizado para determinar se as detecções estão corretas ou não, contribuindo para a avaliação da precisão do algoritmo nas detecções de frutas de tomate.

1.3.9 Aplicação do aprendizado de máquina na produção suína

Nos últimos anos, o uso da tecnologia vem se destacando na pecuária suína. Yang et al. (2018) desenvolveram uma pesquisa para o reconhecimento de alimentação de suínos, usando uma rede neural convolucional de região mais rápida (Faster R-CNN) para reconhecer o comportamento ingestivo de 4 porcas e conseguiram bons resultados.

Em 2019 na pesquisa de Nasirahmadi et al. (2019) foram apresentados três métodos de detecção baseados em aprendizado profundo, incluindo o Faster R-CNN, um detector de caixa única (SSD) e uma rede completamente convolucional baseada em regiões (R-FCN) para detectar suínos deitados e em pé, utilizando imagens coletadas de diversas instalações comerciais e os resultados experimentais indicaram que o método R-FCN ResNet101 foi capaz de detectar posturas deitados e em pé com precisão médias mais altas, alcançando 0,93, 0,95 e 0,92 para posturas em pé e os animais deitados.

Riekert et al. (2021) propuseram a seleção de modelo para detecção de posição e postura de porco em 24 horas por dia, 7 dias por semana usando imagens de câmera 2D e aprendizado profundo, por meio da avaliação de redes de base Inception-v2.

Basak et al. (2020), avaliaram as relações de modelagem entre a temperatura da superfície corporal do porco e o ambiente por meio da utilização de quatro RNAs diferentes, incluindo *Feed Forward Back-propagation* (FFB), *Layer* recorrente (LR), Elman (EL) e *Cascade Forward Back-propagation* (CFB) com diferentes algoritmos de aprendizado, bem como funções de transferência, camadas ocultas e neurônio em cada camada, e modelos de regressão multilinear (MLR) que foram realizados para prever a temperatura corporal do suínos e os resultados mostraram uma maior taxa de desempenho dos modelos RNA em relação ao modelo MLR.

O acompanhamento e monitoramento manual da pecuária tornam-se cada vez mais inviáveis, necessitando de métodos inovadores que auxiliem os produtores, agricultores e pesquisadores a realizarem monitoramento através de recursos tecnológicos de alta precisão, sendo assim, a literatura científica destaca que o algoritmo YOLO é uma técnica que possui ótimo custo/benefício na detecção automática de postura de suínos, tais como postura sentada, em pé e deitada, pois oferece maior desempenho em tempo real, com menos recursos computacionais, sendo capaz de detectar a postura com uma precisão média de 95,9% (SIVAMANI; BASKAR e CHANDRASEKARAN, 2020).

O estudo de Xu et al. (2022) utilizou um modelo combinado de Máquina de Vetor de Suporte de Rede Neural Convolucional (CNN-SVM) para reconhecer e pontuar múltiplas posturas (em pé, sentado, decúbito esternal, decúbito ventral e decúbito lateral) de suínos em condições comerciais com base em imagens de câmera de profundidade Azure Kinect DK e obtiveram 94,6 e 92,21% de precisão no reconhecimento das posturas dos suínos.

Arulmozhi et al. (2021) realizaram o monitoramento e o rastreamento dos comportamentos físicos de suínos usando uma câmera RGB simples por meio de rede neural, baseado em CNN, acoplado a um algoritmo de rastreamento em tempo real (Deep-SORT), implementado para detectar e rastrear a postura de suínos em pé e deitado (esternal e lateral), tanto em grupo quanto individual, utilizando dois modelos de detecção de objetos (YOLOv4 e Faster R-CNN) que foram treinados e comparados seus desempenhos em termos de localização de suínos e detecção de postura, para fins de avaliação das mudanças na postura dos suínos e constataram que o YOLOv4 apresentou os melhores resultados.

Tavares; Meira e Amaral (2020) fez uso da inteligência artificial e realizou estudos para avaliar o comportamento alimentar de suínos nas fases de crescimento e terminação para distintas linhagens e sexos e sua relação com variáveis climáticas (ambiente térmico) e verificou que o YOLOv5 apresentou um R^2 de 0,914, mostrando-se como uma ferramenta de maior precisão e acurácia na predição do comportamento alimentar de suínos nas fases de crescimento e terminação, quando comparada ao modelo fuzzy, o qual apresentou R^2 de 0,858.

Witte e Marx Gómez (2022a), realizaram uma pesquisa para monitorar em tempo real a produção de suínos, possibilitando o estudo da classificação de postura de porco baseada em imagem para detecção de porco e Efficient Net para classificação subsequente de postura de porco em deitado e não-deitado, baseada em métodos de um conjunto de dados de alta qualidade composto por 5.311 imagens heterogêneas de diferentes fontes com 78.215 anotações de caixa delimitadora e os resultados mostraram que o modelo YOLOv5 atinge um AP IoU=0,5 de 0,994 para detecção de suínos.

Zhou (2022a) utilizou YOLOv5 para detectar e realizar a contagem de suínos em comedouros e bebedouros em tempo real e obtiveram resultados satisfatórios, mostrando a viabilidade do modelo para avaliar suínos confinados.

A avaliação da postura de suínos usando o YOLO por meio do teste de um total de 1.792 imagens de classe, envolvendo seis diferentes classes de suínos, mostraram suínos sentados, bem como sua maioria escondidos atrás das barras. Embora o método mostrasse bom desempenho na detecção da postura de suínos, também apresenta falhas em alguns casos, por apresentar resultados com pouca precisão, podendo ser manipulados (SIVAMANI; BASKAR e CHANDRASEKARAN, 2020).

A comparação entre YOLOv5 e ResNet para monitoramento de suínos foi investigada por Wang et al. (2023) na qual centrou-se na estimativa rápida do peso de suínos e observaram que o yolov5 alcançou uma precisão média de 3,9% superior ao outro modelo, demonstrando a sua eficácia nesta aplicação.

A pesquisa de Sivamani; Baskar e Chandrasekaran (2020), realizou treinamento de 5 modelos computacionais para monitorar posturas de suínos (porco em pé, deitado e sentado) e observaram que o YOLOv5 ofereceu maior precisão (0,99) em tempo real, com menos recursos computacionais do que os modelos R-CNN (0,93), R-FCN (0,93), SSD (0,76), SVM (0,94).

Várias outras pesquisas, utilizaram o YOLOv5 no campo da pecuária. Na pesquisa de Qiao; Guo e He (2023) foi utilizado o YOLOv5 para detecção de bovinos, na detecção

de suínos sob oclusão pesada e várias iluminações foram aplicadas por Lai et al. (2023a), na detecção de postura de suínos em ambiente de rebanho foi conduzida por Wang et al. (2023), na estimativa do tamanho corporal dos suínos, reconhecimento do comportamento de galinhas poedeiras e detecção de mamíferos ameaçados foram desenvolvidos por Castañeda et al. (2023).

No estudo conduzido por Luo et al. (2024) foi desenvolvido um método para analisar vídeos, com o objetivo de identificar individualmente suínos e o comportamento alimentar em rebanhos suínos de grande escala e observaram que o YOLOv5 dispensa a necessidade de sensores adicionais ou marcadores individuais.

Referências

- AARON, J.; SPIELMANN, R.; MCARDELL, B. W.; GRAF, C. High-Frequency 3D LiDAR Measurements of a Debris Flow: A Novel Method to Investigate the Dynamics of Full-Scale Events in the Field. **Geophysical Research Letters**, v. 50, n. 5, 2023.
- ADIBHATLA, V. A.; CHIH, H.-C.; HSU, C.-C.; et al. Applying deep learning to defect detection in printed circuit boards via a newest model of you-only-look-once. **Mathematical Biosciences and Engineering**, v. 18, n. 4, p. 4411–4428, 2021.
- AGRAWAL, A. K.; CHAKRABORTY, G. On the use of acquisition function-based Bayesian optimization method to efficiently tune SVM hyperparameters for structural damage detection. **Structural Control and Health Monitoring**, v. 28, n. 4, 2021.
- AHMAD, I.; YANG, Y.; YUE, Y.; et al. Deep Learning Based Detector YOLOv5 for Identifying Insect Pests. **Applied Sciences (Switzerland)**, v. 12, n. 19, 2022.
- AIKOH, T.; HOMMA, R.; ABE, Y. Comparing conventional manual measurement of the green view index with modern automatic methods using google street view and semantic segmentation. **Urban Forestry & Urban Greening**, v. 80, p. 127845, 2023.
- ALAMEER, A.; KYRIAZAKIS, I.; BACARDIT, J. Automated recognition of postures and drinking behaviour for the detection of compromised health in pigs. **Scientific Reports**, v. 10, n. 1, p. 13665, 2020.
- ALBAWI, S. T. A.; MOHAMMED; AL-ZAWI. Understanding of a convolutional neural network. 2017 International Conference on Engineering and Technology (ICET). **Anais...** . p.1–6, 2017. Antalya, Turkey.
- ALBUQUERQUE, C.; HENRIQUES, R.; CASTELLI, M. A stacking-based artificial intelligence framework for an effective detection and localization of colon polyps. **Scientific Reports**, v. 12, n. 1, p. 17678, 2022.
- ALIBRAHIM, H.; LUDWIG, S. A. Hyperparameter Optimization: Comparing Genetic Algorithm against Grid Search and Bayesian Optimization. 2021 IEEE Congress on Evolutionary Computation (CEC). **Anais...** . p.1551–1559, 2021. IEEE.
- ALMEIDA, A. B. C.; ABREU, B. F. L.; TEIXEIRA, G.; et al. ETOLOGIA EQUINA. **Revista Acadêmica do Curso de Medicina Veterinária**, v. 2, p. 7–12, 2022.
- AMARAL, G. R.; XAVIER, F. A inteligência artificial e o novo patamar da interação humano-máquina. **TECCOGS: Revista Digital de Tecnologias Cognitivas**, , n. 26, p. 06–43, 2023.
- ANJOS, A. P.; SILVA, F. A. DA; ALMEIDA, L. L. DE; et al. RECONHECIMENTO DE CÉDULAS DO REAL A PARTIR DE IMAGENS USANDO CNN PARA AUXILIAR DEFICIENTES VISUAIS. **COLLOQUIUM EXACTARUM**, v. 13, n. 1, p. 77–88, 2021.

- ARAFIN, P.; ISSA, A.; BILLAH, A. H. M. M. Performance Comparison of Multiple Convolutional Neural Networks for Concrete Defects Classification. **Sensors**, v. 22, n. 22, p. 8714, 2022.
- ARAÚJO, R. G. R.; GUIMARÃES, T. P.; GOMES, M. R. Influência dos fatores climáticos sobre o desempenho, qualidade de carcaça e carne de suínos: revisão bibliográfica. **Research, Society and Development**, v. 11, n. 3, p. e10711326327, 2022.
- ARNDT, S. S.; GOERLICH, V. C.; VAN DER STAAY, F. J. A dynamic concept of animal welfare: The role of appetitive and adverse internal and external factors and the animal's ability to adapt to them. **Frontiers in Animal Science**, v. 3, 2022.
- ARULMOZHI, E.; BHUJEL, A.; MOON, B.-E.; KIM, H.-T. The Application of Cameras in Precision Pig Farming: An Overview for Swine-Keeping Professionals. **Animals**, v. 11, n. 8, p. 2343, 2021.
- BAÊTA FC, S. C. *Ambiência em edificações rurais - conforto animal*. Editora UFV, p. 246, 1997.
- BAÊTA, F. C.; SOUZA, C. F. **Ambiência em edificações rurais: conforto animal**. Viçosa, 2010.
- BALASAMY, K.; SHAMIA, D. Feature Extraction-based Medical Image Watermarking Using Fuzzy-based Median Filter. **IETE Journal of Research**, v. 69, n. 1, p. 83–91, 2023.
- BARACHO, M.; TOLON, Y. ANÁLISE DE IMAGENS PARA AVALIAÇÃO DO BEM-ESTAR ANIMAL. **AGRARIAN ACADEMY**, v. 9, n. 17, 2022.
- BARELLI, F. **Introdução à Visão Computacional: uma abordagem prática com python e opencv**. 1º ed. São Paulo: Editora Casa do Código, 2019.
- BASAK, J. K.; OKYERE, F. G.; ARULMOZHI, E.; et al. Artificial neural networks and multiple linear regression as potential methods for modelling body surface temperature of pig. **Journal of Applied Animal Research**, v. 48, n. 1, p. 207–219, 2020.
- BASTOS, F. A. S.; VAZ, N. V.; PISARSKI JUNIOR, M. R.; CUNHA, I. C. CARNE SUÍNA, SUA PRODUÇÃO E OS MITOS DO SEU CONSUMO. **Revista Mirante (ISSN 1981-4089)**, v. 16, n. 2, p. 164–179, 2023.
- BENNAI, M. T.; GUESSOUM, Z.; MAZOUZI, S.; CORMIER, S.; MEZGHICHE, M. Multi-agent medical image segmentation: A survey. **Computer Methods and Programs in Biomedicine**, v. 232, p. 107444, 2023.
- BEZERRA, A. C.; BEZERRA DA SILVA, J. L.; DE OLIVEIRA SILVA, D. A.; et al. Monitoramento Espaço-Temporal da Detecção de Mudanças em Vegetação de Caatinga por Sensoriamento Remoto no Semiárido Brasileiro. **Revista Brasileira de Geografia Física**, v. 13, n. 1, p. 286–301, 2020.
- BOCHKOVSKIY, A.; WANG, C. Y.; LIAO, H. Y. M. YOLOv4: Optimal Speed and Accuracy of Object Detection. **arXivpreprintarXiv:2004.10934**, p. 5–29, 2020.

BORTOLOZZO, F. P.; KUMMER, A. B. H. P.; LESSKIU, P. E.; WENTZ, I. Estratégias de redução do catabolismo lactacional manejando a ambiência na maternidade. *Anais....* p.117–131, 2011. Porto Alegre: Simpósio Internacional de Suinocultura, Produção, reprodução e sanidade suína.

BRADFORD, H.; MCKERNAN, C.; ELLIOTT, C.; DEAN, M. Consumers' perceptions and willingness to purchase pork labelled 'raised without antibiotics'. *Appetite*, v. 171, p. 105900, 2022.

BRAGA, A.; CARVALHO, A. P. DE L. F. DE; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 2º ed. Rio de Janeiro, 2007.

BRASIL. Lei Federal nº 11.794/08 (Lei Arouca), de 8 de outubro de 2008 [...] estabelecendo procedimentos para o uso científico de animais [...].

BRITO, A. N. DOS S. L. DE; LOPES NETO, J. P.; FURTADO, D. A.; et al. Desempenho térmico de galpões avícolas para frango de corte: revisão sobre os diferentes tipos de coberturas. *Research, Society and Development*, v. 9, n. 9, p. e474997608, 2020.

BUS, J. D.; BOUMANS, I. J. M. M.; WEBB, L. E.; BOKKERS, E. A. M. The potential of feeding patterns to assess generic welfare in growing-finishing pigs. *Applied Animal Behaviour Science*, v. 241, p. 105383, 2021.

CAGLIARI, T. P.; FRAGA, B. N.; OELKE, C. A.; et al. AVALIAÇÃO DO AMBIENTE EM PESQUISAS SOBRE O COMPORTAMENTO DOS SUÍNOS EM CRESCIMENTO E TERMINAÇÃO: UMA REVISÃO SISTEMÁTICA. *Zootecnia: pesquisa e práticas contemporâneas - Volume 1*. p.208–227, 2021. Editora Científica Digital.

CAMPOS, G. G. DE; SILVA, F. A. DA; ALMEIDA, L. L. DE; et al. ALGORITMO PARA A DETECÇÃO DE ÁRVORES URBANAS A PARTIR DE IMAGENS 360. *COLLOQUIUM EXACTARUM*, v. 15, n. 1, 2023.

CAMPOS, P. H. R. F.; LE FLOC'H, N.; NOBLET, J.; RENAUDEAU, D. Physiological responses of growing pigs to high ambient temperature and/or inflammatory challenges. *Revista Brasileira de Zootecnia*, v. 46, n. 6, p. 537–544, 2017.

CANESCHI, A.; BARDHI, A.; BARBAROSSA, A.; ZAGHINI, A. The Use of Antibiotics and Antimicrobial Resistance in Veterinary Medicine, a Complex Phenomenon: A Narrative Review. *Antibiotics*, v. 12, n. 3, p. 487, 2023.

CARDELLICCHIO, A.; RUGGIERI, S.; NETTIS, A.; RENÒ, V.; UVA, G. Physical interpretation of machine learning-based recognition of defects for the risk management of existing bridge heritage. *Engineering Failure Analysis*, v. 149, p. 107237, 2023.

CARVALHO, C. L.; CAVALCANTE, M. M.; CAMARGO, N. DE O. T.; ANDRETTA, I. BEM-ESTAR ANIMAL EM SUÍNOS. *Suinocultura e Avicultura: Do Básico a Zootecnia de Precisão*, p. 89–115, 2021.

CASTAÑEDA, J. A. J.; DE CASTRO, A. L.; SY, M. A. G.; et al. Development of a Detection System for Endangered Mammals in Negros Island, Philippines Using YOLOv5n. p.435–447, 2023.

DE CASTRO LIPPI, I. C.; CALDARA, F. R.; DE LIMA ALMEIDA PAZ, I. C.; ODAKURA, A. M. Global and Brazilian Scenario of Guidelines and Legislation on Welfare in Pig Farming. **Animals**, v. 12, n. 19, p. 2615, 2022.

CHANG, Y.-H.; ZHANG, Y.-Y. Deep Learning for Clothing Style Recognition Using YOLOv5. **Micromachines**, v. 13, n. 10, p. 1678, 2022.

CHAPA, J. M.; MASCHAT, K.; IWERSEN, M.; BAUMGARTNER, J.; DRILLICH, M. Accelerometer systems as tools for health and welfare assessment in cattle and pigs – A review. **Behavioural Processes**, v. 181, p. 104262, 2020.

CHEN, CHEN; WANG, C.; LIU, B.; et al. Edge Intelligence Empowered Vehicle Detection and Image Segmentation for Autonomous Vehicles. **IEEE Transactions on Intelligent Transportation Systems**, v. 24, n. 11, p. 13023–13034, 2023.

CHEN, GUOMING; CHEN, Q.; LONG, S.; et al. Quantum convolutional neural network for image classification. **Pattern Analysis and Applications**, v. 26, n. 2, p. 655–667, 2023.

CHEN, JIAOCHEN; CAI, Z.; CHEN, H.; et al. Renal Pathology Images Segmentation Based on Improved Cuckoo Search with Diffusion Mechanism and Adaptive Beta-Hill Climbing. **Journal of Bionic Engineering**, v. 20, n. 5, p. 2240–2275, 2023.

CHEN, JIARUI; LI, W.; YANG, P.; LI, S.; CHEN, B. Fault Diagnosis of Electric Submersible Pumps Using a Three-Stage Multiscale Feature Transformation Combined with CNN–SVM. **Energy Technology**, v. 11, n. 10, 2023.

CHEN, S.; ZOU, X.; ZHOU, X.; XIANG, Y.; WU, M. Study on fusion clustering and improved YOLOv5 algorithm based on multiple occlusion of *Camellia oleifera* fruit. **Computers and Electronics in Agriculture**, v. 206, p. 107706, 2023.

DA COSTA, A. Z.; FIGUEROA, H. E. H.; FRACAROLLI, J. A. Computer vision based detection of external defects on tomatoes using deep learning. **Biosystems Engineering**, v. 190, p. 131–144, 2020.

COSTA, D. A. DA; SANTOS, V. M. DOS; OLIVEIRA, A. V. D. DE; et al. Efeito da sazonalidade sobre as respostas fisiológicas e produtivas de vacas leiteiras mestiças ao clima amazônico equatorial. **Ciência Animal Brasileira**, v. 24, 2023.

DAI, G.; HU, L.; FAN, J. DA-ActNN-YOLOV5: Hybrid YOLO v5 Model with Data Augmentation and Activation of Compression Mechanism for Potato Disease Identification. **Computational Intelligence and Neuroscience**, v. 2022, p. 1–16, 2022.

DAI, G.; HU, L.; FAN, J.; YAN, S.; LI, R. A Deep Learning-Based Object Detection Scheme by Improving YOLOv5 for Sprouted Potatoes Datasets. **IEEE Access**, v. 10, p. 85416–85428, 2022.

DALLABRIDA, V. E.; RODRIGUES CALIXTO, S.; KOSLINSKI, A.; et al. Relato de caso: a Medicina Veterinária Forense na identificação de maus tratos em galos (*Gallus gallus domesticus*) utilizados com a finalidade de rinha. **Revista Brasileira de Criminalística**, v. 12, n. 5, p. 47–53, 2023.

DALLA ROSA, F.; FAVRETTO, L. D.; RODRIGUES, V. B.; GHARAIBEH, N. G. Convolutional neural networks performance evaluation applied to automated pavement crack detection. **TRANSPORTES**, v. 28, n. 5, p. 267–279, 2020.

DEGAKI, R. H.; COLONNA, J. G.; LOPEZ, Y.; CARVALHO, J. R.; SILVA, E. Real Time Detection of Mobile Graphical User Interface Elements Using Convolutional Neural Networks. Proceedings of the Brazilian Symposium on Multimedia and the Web. **Anais...** . p.159–167, 2022. New York, NY, USA: ACM.

DEXTRE, M.; ROSAS, O.; LAZO, J.; GUTIERREZ, J. C. Gun Detection in Real-Time, using YOLOv5 on Jetson AGX Xavier. 2021 XLVII Latin American Computing Conference (CLEI). **Anais...** . p.1–7, 2021. IEEE.

DHIMAN, G.; KUMAR, A. V.; NIRMALAN, R.; et al. Multi-modal active learning with deep reinforcement learning for target feature extraction in multi-media image processing applications. **Multimedia Tools and Applications**, v. 82, n. 4, p. 5343–5367, 2023.

DONG, Q.; WANG, S.; CHEN, X.; et al. Pavement crack detection based on point cloud data and data fusion. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 381, n. 2254, 2023.

DYKE, R. M.; HORMANN, K. Histogram equalization using a selective filter. **The Visual Computer**, v. 39, n. 12, p. 6221–6235, 2023.

EKICI, S.; JAWZAL, H. Breast cancer diagnosis using thermography and convolutional neural networks. **Medical Hypotheses**, v. 137, p. 109542, 2020.

ELGELDAWI, E.; SAYED, A.; GALAL, A. R.; ZAKI, A. M. Hyperparameter Tuning for Machine Learning Algorithms Used for Arabic Sentiment Analysis. **Informatics**, v. 8, n. 4, p. 79, 2021.

ELMASRY, G.; ELGAMAL, R.; MANDOUR, N.; et al. Emerging thermal imaging techniques for seed quality evaluation: Principles and applications. **Food Research International**, v. 131, p. 109025, 2020.

ESCOBAR, L. S.; NASCIMENTO, J. D. DO; GALHARDO, A. G.; et al. Percepção de consumidores da relação entre qualidade da carne e bem-estar animal. **Revista em Agronegócio e Meio Ambiente**, v. 15, n. 4, p. 1–14, 2022.

FELIPE, B.; SILVA, B. F. C.; DE LA, E. D. S. V.; SILVA, F.; SILVA, D. C. M. N.; da SILVA, L. P.; SILVA, A. S. C. M. R. Principais impactos ambientais ocasionados pelo manejo inadequado dos dejetos de suínos–Revisão de Literatura. **Fórum Rondoniense de Pesquisa**, v. 1, n. 6, 2020.

FERNANDES, A. F. A.; DÓREA, J. R. R.; FITZGERALD, R.; HERRING, W.; ROSA, G. J. M. A novel automated system to acquire biometric and morphological measurements and predict body weight of pigs via 3D computer vision1. **Journal of Animal Science**, v. 97, n. 1, p. 496–508, 2019.

FERNANDES, A. F. A.; DÓREA, J. R. R.; ROSA, G. J. DE M. Image Analysis and Computer Vision Applications in Animal Sciences: An Overview. **Frontiers in Veterinary Science**, v. 7, 2020a.

FERNANDES, A. F. A.; DÓREA, J. R. R.; ROSA, G. J. DE M. Image Analysis and Computer Vision Applications in Animal Sciences: An Overview. **Frontiers in Veterinary Science**, v. 7, 2020b.

FERNANDO, D. M. Z.; OLIVEIRA JÚNIOR, A. J. DE; NORIS, F. J.; RASO, E. F. Variabilidade do conforto térmico de aves de corte nas condições de ambiente natural em Chimoio - Moçambique. **Research, Society and Development**, v. 11, n. 6, p. e13911628826, 2022.

FERRARI, D.; CAMARGO, S. C. Comportamento de suínos em fase de terminação em diferentes tipos de piso. **Revista JRG de Estudos Acadêmicos**, v. 6, n. 13, p. 415–429, 2023.

FERRAZ JARDIM, A. M. DA R.; DE QUEIROZ, M. G.; ARAÚJO JÚNIOR, G. D. N.; DA SILVA, M. J.; FREIRE DA SILVA, T. G. ESTUDOS CLIMÁTICOS DO NÚMERO DE DIAS DE PRECIPITAÇÃO PLUVIAL PARA O MUNICÍPIO DE SERRA TALHADA-PE. **REVISTA ENGENHARIA NA AGRICULTURA - REVENG**, v. 27, n. 4, p. 330–337, 2019.

FERREIRA, J. A.; VALENTIM, J. K.; MACHADO, L. C.; FREITAS DE OLIVEIRA, H. Aplicação de Etogramas no Bem-Estar de Aves: uma Revisão de Literatura. **UNICIÊNCIAS**, v. 26, n. 1, p. 24–30, 2022.

DE FIGUEIREDO, E. A. P.; COSTA, O. A. D.; COLDEBELA, A.; BERTOL, T. M.; DE LIMA, G. J. M. Desempenho de suínos de genótipos para sistemas convencionais e alternativos de produção. **Brazilian Journal of Animal and Environmental Research**, v. 6, n. 2, p. 1001–1017, 2023.

FREITAS, D. S. DE; CAMARGO, S. D. S.; COMIN, H. B.; et al. Reconhecimento da ceratoconjuntivite infecciosa bovina utilizando imagens termográficas e redes neurais convolucionais. **Revista Brasileira de Computação Aplicada**, v. 11, n. 3, p. 133–145, 2019.

FU, Z.; LI, J.; HUA, Z.; FAN, L. Deep supervision feature refinement attention network for medical image segmentation. **Engineering Applications of Artificial Intelligence**, v. 125, p. 106666, 2023.

GALDIOLI, L.; CAPILÉ, K. V.; DE OLIVEIRA, H. V. G.; NUNES, V. P.; JUNIOR, V. D. P. A. FOIE GRAS: DO REQUINTE À CRUELDADE. **Archives of Veterinary Science**, v. 27, n. 2, 2022.

GATES, M.; HOLMSTROM, L.; BIGGERS, K.; BECKHAM, T. Integrating novel data streams to support biosurveillance in commercial livestock production systems in developed countries: challenges and opportunities. **Frontiers in Public Health**, v. 3, 2015.

GHAREHCHOPOGH, F. S.; IBRIKCI, T. An improved African vultures optimization algorithm using different fitness functions for multi-level thresholding image segmentation. **Multimedia Tools and Applications**, v. 83, n. 6, p. 16929–16975, 2023.

- GIEŁCZYK, A.; MARCINIAK, A.; TARCZEWSKA, M.; LUTOWSKI, Z. Pre-processing methods in chest X-ray image classification. **PLOS ONE**, v. 17, n. 4, p. e0265949, 2022.
- GOMES, N. F.; BARNABE, J. M. C.; SILVA, W. A.; PANDORFI, H. ; GUISELINI, C.; ALMEIDA, G. L. P. Acondicionamento térmico para suínos na fase de crescimento no semiárido pernambucano. **Simpósio Internacional de Ambiência e Engenharia na Produção Animal**, v. 2, p. 171–177, 2019.
- GOMES, N. F.; PANDORFI, H.; BARNABÉ, J. M. C.; et al. Navegando en aguas abiertas: tensiones y agentes en la conservación marina en la Patagonia chilena. **Revista de Estudios Sociales**, , n. 64, p. 27–41, 2018.
- GÓMEZ-PRADO, J.; PEREIRA, A. M. F.; WANG, D.; et al. Thermoregulation mechanisms and perspectives for validating thermal windows in pigs with hypothermia and hyperthermia: An overview. **Frontiers in Veterinary Science**, v. 9, 2022.
- GONÇALVES DE OLIVEIRA, D. C.; DI CAMPOS, M. S.; PASSÉ-COUTRIN, N.; et al. Modeling of the thermal performance of piglet house with non-conventional floor system. **Journal of Building Engineering**, v. 35, p. 102071, 2021.
- GUEVARA, R. D.; PASTOR, J. J.; MANTECA, X.; TEDO, G.; LLONCH, P. Systematic review of animal-based indicators to measure thermal, social, and immune-related stress in pigs. **PLOS ONE**, v. 17, n. 5, p. e0266524, 2022.
- GUI, Z.; CHEN, J.; LI, Y.; et al. A lightweight tea bud detection model based on Yolov5. **Computers and Electronics in Agriculture**, v. 205, p. 107636, 2023.
- GÜNTHER, F.; MARELLI, M.; TURESKI, S.; PETILLI, M. A. ViSpa (Vision Spaces): A computer-vision-based representation system for individual images and concept prototypes, with large-scale evaluation. **Psychological Review**, v. 130, n. 4, p. 896–934, 2023.
- GUO, L.; SHI, P.; CHEN, L.; CHEN, C.; DING, W. Pixel and region level information fusion in membership regularized fuzzy clustering for image segmentation. **Information Fusion**, v. 92, p. 479–497, 2023.
- GUPTA, H.; SINGH, H.; KUMAR, A.; VISHWAKARMA, A.; SINGH, G. K. Variational mode decomposition based image denoising using semi-adaptive conductance function inspired diffusion filtering. **Multimedia Tools and Applications**, v. 83, n. 3, p. 7433–7456, 2024.
- GUPTA, J.; PATHAK, S.; KUMAR, G. Deep Learning (CNN) and Transfer Learning: A Review. **Journal of Physics: Conference Series**, v. 2273, n. 1, p. 012029, 2022.
- HABINEZA, E.; REZA, MD. N.; CHOWDHURY, M.; SHAFIK, K. Pig diseases and crush monitoring visual symptoms detection using engineering approaches: A review. **Precision Agriculture Science and Technology**, v. 3, n. 4, 2021.
- HAN, Q.; WANG, H.; HOU, M.; et al. HWA-SegNet: Multi-channel skin lesion image segmentation network with hierarchical analysis and weight adjustment. **Computers in Biology and Medicine**, v. 152, p. 106343, 2023.

HARSHAVARDHAN, Y.; NALINI, N. Comparative analysis of accuracy in identification of bone fracture detection using Prewitt edge detection with Sobel edge detection approach. . p.020032, 2023.

HE, Y.; GE, R.; QI, X.; et al. Learning Better Registration to Learn Better Few-Shot Medical Image Segmentation: Authenticity, Diversity, and Robustness. **IEEE Transactions on Neural Networks and Learning Systems**, v. 35, n. 2, p. 2588–2601, 2024.

HOSNY, K. M.; KHALID, A. M.; HAMZA, H. M.; MIRJALILI, S. Multilevel thresholding satellite image segmentation using chaotic coronavirus optimization algorithm with hybrid fitness function. **Neural Computing and Applications**, v. 35, n. 1, p. 855–886, 2023.

HUANG, J.; RAJA, J.; CANTOR, C.; et al. Eye Motion Tracking for Medical Image Interpretation Training. **Current Problems in Diagnostic Radiology**, v. 52, n. 6, p. 474–477, 2023.

HUANG, Z.; FU, H.; FAN, X.; et al. Rapid Surface Damage Detection Equipment for Subway Tunnels Based on Machine Vision System. **Journal of Infrastructure Systems**, v. 27, n. 1, 2021.

HU, M.; ZHANG, J.; MATKOVIC, L.; LIU, T.; YANG, X. Reinforcement learning in medical image analysis: Concepts, applications, challenges, and future directions. **Journal of Applied Clinical Medical Physics**, v. 24, n. 2, 2023.

HUSSAIN, A.; KHUNTETA, A. Semantic Segmentation of Brain Tumor from MRI Images and SVM Classification using GLCM Features. 2020 Second International Conference on Inventive Research in Computing Applications (ICIRCA). **Anais...** . p.38–43, 2020. IEEE.

HU, Z.; YANG, Q.; TAO, Y.; et al. A review of ventilation and cooling systems for large-scale pig farms. **Sustainable Cities and Society**, v. 89, p. 104372, 2023a.

HU, Z.; YANG, Q.; TAO, Y.; et al. A review of ventilation and cooling systems for large-scale pig farms. **Sustainable Cities and Society**, v. 89, p. 104372, 2023b.

IMAMURA, M. E.; SILVA, F. A. DA; ALMEIDA, L. L. DE; et al. DETECÇÃO E RECONHECIMENTO DE PLACAS DE LICENCIAMENTO VEICULAR EM TEMPO REAL USANDO CNN. **COLLOQUIUM EXACTARUM**, v. 13, n. 1, p. 89–99, 2021.

INOCÊNCIO, M. V.; ARTERO, A. O.; ELER, D. M.; SILVA, F. A. DA; PEREIRA, D. R. Equalização e segmentação de imagens usando informações de cores. **Colloquium Exactarum**, v. 12, n. 1, p. 20–38, 2020.

JAMES, C.; GU, Y.; POTGIETER, A.; et al. From Prototype to Inference: A Pipeline to Apply Deep Learning in Sorghum Panicle Detection. **Plant Phenomics**, v. 5, 2023.

JANA, B. R.; THOTAKURA, H.; BALIYAN, A.; et al. Pixel density based trimmed median filter for removal of noise from surface image. **Applied Nanoscience**, v. 13, n. 2, p. 1017–1028, 2023.

JOCHER, G.; NISHIMURA, K.; MINEEVA, T.; VILARINO, R. Yolov5 by ultralytics.

JOHNSON, J. S.; STEWART, K. R.; SAFRANSKI, T. J.; ROSS, J. W.; BAUMGARD, L. H. In utero heat stress alters postnatal phenotypes in swine. **Theriogenology**, v. 154, p. 110–119, 2020.

JOHN, S.; ROSE PETER JOSEPH, A. L. Preprocessing of leaf images using brightness preserving dynamic fuzzy histogram equalization technique. **IAES International Journal of Artificial Intelligence (IJ-AI)**, v. 12, n. 3, p. 1149, 2023.

JORQUERA-CHAVEZ, M.; FUENTES, S.; DUNSHEA, F. R.; et al. Using imagery and computer vision as remote monitoring methods for early detection of respiratory disease in pigs. **Computers and Electronics in Agriculture**, v. 187, p. 106283, 2021.

JUNG, D.; CHOI, Y. Systematic Review of Machine Learning Applications in Mining: Exploration, Exploitation, and Reclamation. **Minerals**, v. 11, n. 2, p. 148, 2021.

JUNLONG, W.; WEI, K.; WEI, Z.; et al. Helmet Detection Algorithm Based on the Improved YOLOv5 and Dynamic Anchor Box Matching. 2021 IEEE International Conference on Emergency Science and Information Technology (ICESIT). **Anais...** . p.79–83, 2021. IEEE.

JUSTINO, E.; NÄÄS, I. A.; CARVALHO, T. M. R.; SALGADO, D. A. Efeito do resfriamento evaporativo e do balanço eletrolítico sobre a lactação de porcas em condições de verão tropical. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**, p. 455–464, 2015.

KASPER-EULAERS, M.; HAHN, N.; BERGER, S.; et al. Short Communication: Detecting Heavy Goods Vehicles in Rest Areas in Winter Conditions Using YOLOv5. **Algorithms**, v. 14, n. 4, p. 114, 2021.

KATARAS, T. J.; JANG, T. J.; KOURY, J.; et al. ACCT is a fast and accessible automatic cell counting tool using machine learning for 2D image segmentation. **Scientific Reports**, v. 13, n. 1, p. 8213, 2023.

KIEFER, C., MEIGNEN, B. C. G., SANCHES, J. F., & CARRIJO, A. S. Resposta de suínos em crescimento mantidos em diferentes temperaturas. **Archivos de zootecnia**, v. 58, n. 221, p. 55–64, 2009.

KIEFER, C.; MOURA, M. S. DE; SILVA, E. A. DA; et al. Respostas de suínos em terminação mantidos em diferentes ambientes térmicos. **Revista brasileira de Saúde Produção Animal**, v. 11, n. 2, p. 496–504, 2010.

KIM, B.; REDDY, K. E.; KIM, H. R.; et al. Effects of recovery from short-term heat stress exposure on feed intake, plasma amino acid profiles, and metabolites in growing pigs. **Journal of Animal Science and Technology**, v. 63, n. 3, p. 531–544, 2021.

KIM, J.; LEE, Y.-K.; CHOI, C.-S.; FERESHTEJAD, S.; SONG, J.-J. Scanline intersection similarity: A similarity metric for joint trace maps. **Computers & Geosciences**, v. 175, p. 105358, 2023.

KIRIMTAT, A.; KREJCAR, O.; SELAMAT, A.; HERRERA-VIEDMA, E. FLIR vs SEEK thermal cameras in biomedicine: comparative diagnosis through infrared thermography. **BMC Bioinformatics**, v. 21, n. S2, p. 88, 2020.

- KOCH, P.; GOLOVIDOV, O.; GARDNER, S.; et al. Autotune. Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. **Anais...** . p.443–452, 2018. New York, NY, USA: ACM.
- KONG, W.; CHEN, J.; SONG, Y.; et al. Sobel Edge Detection Algorithm with Adaptive Threshold based on Improved Genetic Algorithm for Image Processing. **International Journal of Advanced Computer Science and Applications**, v. 14, n. 2, 2023.
- KRICHEN, M. Convolutional Neural Networks: A Survey. **Computers**, v. 12, n. 8, p. 151, 2023.
- KRSTINIĆ, D.; ŠERIĆ, L.; SLAPNIČAR, I. Comments on “MLCM: Multi-Label Confusion Matrix”. **IEEE Access**, v. 11, p. 40692–40697, 2023.
- KRUGER, S. D.; PAULUS LINK, C. ANÁLISE DE PRÁTICAS DE SUSTENTABILIDADE EM GRANJAS SUINÍCOLAS. **Revista Gestão Organizacional**, v. 16, n. 3, p. 161–179, 2023.
- KULSHRESHTHA, A.; NAGPAL, A. Brain image segmentation using variation in structural elements of morphological operators. **International Journal of Information Technology**, v. 15, n. 4, p. 2283–2291, 2023.
- LAI, J.; LIANG, Y.; KUANG, Y.; et al. IO-YOLOv5: Improved Pig Detection under Various Illuminations and Heavy Occlusion. **Agriculture**, v. 13, n. 7, p. 1349, 2023.
- LARSEN, M. L. V.; WANG, M.; NORTON, T. Information Technologies for Welfare Monitoring in Pigs and Their Relation to Welfare Quality®. **Sustainability**, v. 13, n. 2, p. 692, 2021.
- LAWAL, O. M.; ZHU, S.; CHENG, K. An improved YOLOv5s model using feature concatenation with attention mechanism for real-time fruit detection and counting. **Frontiers in Plant Science**, v. 14, 2023.
- LAWRENCE, A. B.; NEWBERRY, R. C.; ŠPINKA, M. Positive welfare: What does it add to the debate over pig welfare? **Advances in Pig Welfare**, p. 83–112, 2024.
- LEE, W.; HAM, Y.; BAN, T.-W.; JO, O. Analysis of Growth Performance in Swine Based on Machine Learning. **IEEE Access**, v. 7, p. 161716–161724, 2019.
- LEI, F.; TANG, F.; LI, S. Underwater Target Detection Algorithm Based on Improved YOLOv5. **Journal of Marine Science and Engineering**, v. 10, n. 3, p. 310, 2022.
- DE LEMOS, M. J.; BRAGA, T. V. S.; LEITE, D. K. V. H.; GALINDO, E. L. DE O. Efeito climático sobre a produção de leite de vacas Guzerá criadas em dois ambientes diferentes. **Brazilian Journal of Animal and Environmental Research**, v. 6, n. 2, p. 1721–1726, 2023.
- LIASHCHYNSKYI, P.; LIASHCHYNSKYI, P. GridSearch,RandomSearch,GeneticAlgorithm:ABig ComparisonforNAS. **arXiv:1912.06059**, 2019.

- LI, FANGNING; WU, D.; ZHU, D.; SHEN, M. Airborne radar forward-looking image enhancing algorithm based on generative adversarial networks. **Electronics Letters**, v. 59, n. 14, 2023.
- LI, HAOPU; LI, HAOMING; LI, B.; et al. Smart Temperature and Humidity Control in Pig House by Improved Three-Way K-Means. **Agriculture**, v. 13, n. 10, p. 2020, 2023.
- LI, JIALE; PAN, H.; LI, JUNFENG. ESD-YOLOv5: A Full-Surface Defect Detection Network for Bearing Collars. **Electronics**, v. 12, n. 16, p. 3446, 2023.
- LI, JINGZHENG; SUN, H.; LI, JIYI. Beyond confusion matrix: learning from multiple annotators with awareness of instance features. **Machine Learning**, v. 112, n. 3, p. 1053–1075, 2023.
- LI, L.; YANG, Z.; DANG, Z.; et al. Propagation analysis and prediction of the COVID-19. **Infectious Disease Modelling**, v. 5, p. 282–292, 2020.
- LIMA, A. V. DE; MEDEIROS, C. J. DE; PANDORFI, H.; HOLANDA, M. C. R. DE; HOLANDA, M. A. C. DE. Desempenho zootécnico de suínos em terminação submetidos a diferentes programas de iluminação em ambientes climatizados. **Research, Society and Development**, v. 11, n. 3, p. e26211325699, 2022.
- LIN, M.-Y.; HSIEH, S.-H.; CHEN, C.-H. Reconfigurable Hardware Accelerator of Morphological Image Processor. 2023 IEEE 3rd International Conference on Electronic Communications, Internet of Things and Big Data (ICEIB). **Anais...** . p.348–351, 2023. IEEE.
- LIU, F.; GAO, L.; WAN, J.; et al. Recognition of Digital Dental X-ray Images Using a Convolutional Neural Network. **Journal of Digital Imaging**, v. 36, n. 1, p. 73–79, 2022.
- LIU, Y.; PU, H.; SUN, D.-W. Efficient extraction of deep image features using convolutional neural network (CNN) for applications in detecting and analysing complex food matrices. **Trends in Food Science & Technology**, v. 113, p. 193–204, 2021.
- LI, YUAN; DELFINO, J.; ZENG, R. Utility of phantom-based testing for evaluating the performance of AI in MRI image reconstruction. In: R. Fahrig; J. M. Sabol; L. Yu (Orgs.); *Medical Imaging 2023: Physics of Medical Imaging*. **Anais...** . p.113, 2023. SPIE.
- LI, Y.; LIU, L. YOLO-ResNet: A New Model for Rebar Detection. 2021 4th International Conference on Robotics, Control and Automation Engineering (RCAE). **Anais...** . p.128–132, 2021. IEEE.
- LI, YOU; MOREAU, J.; IBANEZ-GUZMAN, J. Emergent Visual Sensors for Autonomous Vehicles. **IEEE Transactions on Intelligent Transportation Systems**, v. 24, n. 5, p. 4716–4737, 2023.
- LONG, W.; ZHU, B.; LI, H.; et al. Grid Side Distributed Energy Storage Cloud Group End Region Hierarchical Time-Sharing Configuration Algorithm Based on Multi-Scale and Multi Feature Convolution Neural Network. **Energy Engineering**, v. 120, n. 5, p. 1253–1269, 2023.
- LOTUFO, R. A.; AUDIGIER, R.; SAÚDE, A. V.; MACHADO, R. C. Morphological Image Processing. **Microscope Image Processing**. p.75–117, 2023. Elsevier.

LUO, H.; U, K.; ZHAO, W. Multi-focus image fusion through pixel-wise voting and morphology. **Multimedia Tools and Applications**, v. 82, n. 1, p. 899–925, 2023.

LUO, Y.; XIA, J.; LU, H.; et al. Automatic Recognition and Quantification Feeding Behaviors of Nursery Pigs Using Improved YOLOV5 and Feeding Functional Area Proposals. **Animals**, v. 14, n. 4, p. 569, 2024.

LUXIMON, A.; CHAO, H.; GOONETILLEKE, R. S.; LUXIMON, Y. Theory and applications of InfraRed and thermal image analysis in ergonomics research. **Frontiers in Computer Science**, v. 4, 2022.

MAES, D. G. D.; DEWULF, J.; PIÑEIRO, C.; EDWARDS, S.; KYRIAZAKIS, I. A critical reflection on intensive pork production with an emphasis on animal health and welfare. **Journal of Animal Science**, v. 98, n. Supplement_1, p. S15–S26, 2020.

MAHFUZ, S.; MUN, H.-S.; DILAWAR, M. A.; YANG, C.-J. Applications of Smart Technology as a Sustainable Strategy in Modern Swine Farming. **Sustainability**, v. 14, n. 5, p. 2607, 2022.

MANNO, M. C.; OLIVEIRA, R. F. M.; DONZELE, J. L. Efeito da temperatura ambiente sobre o desempenho de suínos dos 15 aos 30kg. **Revista Brasileira de Zootecnia**, v. 34, n. 6, p. 1963–1970, 2005.

MARCONI, G.; CARNOVALE, F.; ARNEY, D.; DE ROSA, G.; NAPOLITANO, F. Relevance of animal-based indicators for the evaluation of sheep welfare as perceived by different stakeholders. **Small Ruminant Research**, v. 217, p. 106827, 2022.

MARSOT, M.; MEI, J.; SHAN, X.; et al. An adaptive pig face recognition approach using Convolutional Neural Networks. **Computers and Electronics in Agriculture**, v. 173, p. 105386, 2020.

MASOUDI, S.; HARMON, S. A.; MEHRALIVAND, S.; et al. Quick guide on radiology image pre-processing for deep learning applications in prostate cancer research. **Journal of Medical Imaging**, v. 8, n. 01, 2021.

MASSARI, J. M.; CURI, T. M. R. DE C.; MOURA, D. J.; MEDEIROS, B. B. L.; SALGADO, D. D. Características comportamentais de suínos em crescimento e terminação em sistema “wean to finish”. **Engenharia Agrícola**, v. 35, n. 4, p. 646–656, 2015.

MATTHEWS, S.; MILLER, A.; PLÖTZ, T.; KYRIAZAKIS, I. Automated tracking to measure behavioural changes in pigs for health and welfare monitoring. **Scientific Reports**, n° 7, v. 1, 2017.

MATOS, W. DE; MENEGOTI, J. P.; PAULA, U. F. DE; et al. Principais causas de condenação de carcaças de suínos em frigorífico, sob o crivo do serviço de inspeção estadual, no município de Ji-Paraná – RO. **Research, Society and Development**, v. 11, n. 8, p. e14311830608, 2022.

MEHDIZADEH, M.; TAVAKOLI TAFTI, K.; SOLTANI, P. Evaluation of histogram equalization and contrast limited adaptive histogram equalization effect on image quality

and fractal dimensions of digital periapical radiographs. **Oral Radiology**, v. 39, n. 2, p. 418–424, 2023.

MENG, X.; LIU, Y.; FAN, L.; FAN, J. YOLOv5s-Fog: An Improved Model Based on YOLOv5s for Object Detection in Foggy Weather Scenarios. **Sensors**, v. 23, n. 11, p. 5321, 2023.

MESSINA, G.; MODICA, G. Applications of UAV Thermal Imagery in Precision Agriculture: State of the Art and Future Research Outlook. **Remote Sensing**, v. 12, n. 9, p. 1491, 2020.

MOHIYUDDIN, A.; BASHARAT, A.; GHANI, U.; et al. Breast Tumor Detection and Classification in Mammogram Images Using Modified YOLOv5 Network. **Computational and Mathematical Methods in Medicine**, v. 2022, p. 1–16, 2022.

MONTEIRO, B. P.; LASCELLES, B. D. X.; MURRELL, J.; et al. 2022 <scp>WSAVA</scp> guidelines for the recognition, assessment and treatment of pain. **Journal of Small Animal Practice**, v. 64, n. 4, p. 177–254, 2023.

MOTA, L. T.; SILVA, L. F. DA; MENEGALI, I.; SILVA, B. A. N. ANÁLISE ESTRUTURAL DE INSTALAÇÕES SUINÍCOLAS VISANDO MELHORIAS NOS ÍNDICES DE CONFORTO TÉRMICO. **ENERGIA NA AGRICULTURA**, v. 34, n. 3, p. 389–398, 2019.

MURSAL, A. S. N.; IBRAHIM, H. Median Filtering Using First-Order and Second-Order Neighborhood Pixels to Reduce Fixed Value Impulse Noise from Grayscale Digital Images. **Electronics**, v. 9, n. 12, p. 2034, 2020.

NARAYAN, F.; MALL, P. K.; AWASTHI, S.; SRIVASTAVA, A. FuzzyNet: Medical Image Classification based on GLCM Texture Feature. Conferência Internacional sobre Inteligência Artificial e Comunicação Inteligente (AISC). **Anais...**, 2023. Grande Noida, Índia,.

NARAYAN, V.; FAIZ, M.; MALL, P. K.; SRIVASTAVA, S. A Comprehensive Review of Various Approach for Medical Image Segmentation and Disease Prediction. **Wireless Personal Communications**, v. 132, n. 3, p. 1819–1848, 2023.

NASIRAHMADI, A.; STURM, B.; EDWARDS, S.; et al. Deep Learning and Machine Vision Approaches for Posture Detection of Individual Pigs. **Sensors**, v. 19, n. 17, p. 3738, 2019.

NAUTA, M.; HEGEMAN, J. H.; GEERDINK, J.; et al. Interpreting and Correcting Medical Image Classification with PIP-Net. . p.198–215, 2024.

NEETHIRAJAN, S.; REIMERT, I.; KEMP, B. Measuring Farm Animal Emotions—Sensor-Based Approaches. **Sensors**, v. 21, n. 2, p. 553, 2021.

NEMATZADEH, S.; KIANI, F.; TORKAMANIAN-AFSHAR, M.; AYDIN, N. Tuning hyperparameters of machine learning algorithms and deep neural networks using metaheuristics: A bioinformatics study on biomedical and biological cases. **Computational Biology and Chemistry**, v. 97, p. 107619, 2022.

- NEPAL, U.; ESLAMIAT, H. Comparing YOLOv3, YOLOv4 and YOLOv5 for Autonomous Landing Spot Detection in Faulty UAVs. **Sensors**, v. 22, n. 2, p. 464, 2022.
- NETA, A. M. R.; DA SILVA, E. A.; FRANCO, E. DE S.; DA COSTA, A. C. M. DE S. F. Bem-estar animal: Reflexo do manejo adequado no transporte de suínos / Animal welfare: Reflection of proper handling in the transport of pigs. **Brazilian Journal of Development**, v. 7, n. 12, p. 114851–114869, 2021.
- OIE - ORGANIZAÇÃO INTERNACIONAL DE EPIZOOTIAS. Terrestrial Animal Health Code. .
- OKINDA, CEDRIC; NYALALA, I.; KOROHOU, T.; et al. A review on computer vision systems in monitoring of poultry: A welfare perspective. **Artificial Intelligence in Agriculture**, v. 4, p. 184–208, 2020.
- OLIVEIRA ALVES, D.; PRZYVARA RIZZATTI, E.; ALVES FEITOSA FILHO, L.; GRISA HAHN, K. Custo de produção da suinocultura: comparativo de rentabilidade da suinocultura de cria e recria nos períodos de 2019 a 2022, em uma unidade produtiva situada no município de Ampére no Sudoeste do Paraná. **RECIMA21 - Revista Científica Multidisciplinar - ISSN 2675-6218**, v. 4, n. 1, p. e414465, 2023.
- OLIVEIRA, J. K. M. DE; MELO, D. B. A.; ALVES, M. D.; et al. Effects of lowering dietary protein content without or with increased protein-bound and feed-grade amino acids supply on growth performance, body composition, metabolism, and acute-phase protein of finishing pigs under daily cyclic heat stress. **Journal of Animal Science**, v. 101, 2023.
- OLIVEIRA, M. J. K. DE; VALK, M.; MELO, A. D. B.; et al. Feeding Behavior of Finishing Pigs under Diurnal Cyclic Heat Stress. **Animals**, v. 13, n. 5, p. 908, 2023.
- DE OLIVEIRA SANTANA, E.; MARCONDES, L.; ALVES DA SILVA, L. A.; et al. Imagem guiada para qualidade de vida de mulheres com câncer cervical: estudo quase experimental. **Revista Cuidarte**, v. 14, n. 1, 2023.
- PADILLA, R.; PASSOS, W. L.; DIAS, T. L. B.; NETTO, S. L.; DA SILVA, E. A. B. A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit. **Electronics**, v. 10, n. 3, p. 279, 2021.
- PAES, A. S. L. RECONHECIMENTO AUTOMÁTICO DE PLACAS DE AUTOMÓVEIS UTILIZANDO REDES DE KOHONEN . , 2017. Rio de Janeiro.
- PANDEY, S.; KALWA, U.; KONG, T.; et al. Behavioral Monitoring Tool for Pig Farmers: Ear Tag Sensors, Machine Intelligence, and Technology Adoption Roadmap. **Animals**, v. 11, n. 9, p. 2665, 2021.
- PANDORFI, H.; GUISELINI, C.; ALMEIDA, G. L. P.; SILVA, R. A. B.; GOMES, N. F. Suinocultura de precisão: Visão computacional e tecnologias digitais. **Revista Científica De Produção Animal**, v. 22, n. 2, p. 73–79, 2020.
- PANDORFI, H.; SILVA, I. J. O. Evaluation of the behavior of piglets in different heating systems using analysis of image and electronic identification. **Agricultural Engineering International**, v. 7, n. 8, p. 1–24, 2005.

- PANDORFI, H.; SILVA, I. J. O. DA; PIEDADE, S. M. S. Conforto térmico para matrizes suínas em fase de gestação, alojadas em baias individuais e coletivas. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 12, n. 3, p. 326–332, 2008.
- PARREIRA, D. P.; VALENTIM, J. K.; GERALDO, A.; et al. Suínos em fase de terminação mantidos em ambiente enriquecido. **Caderno de Ciências Agrárias**, v. 13, p. 1–6, 2021.
- PATHAK, S. P.; PATIL, S. A. Evaluation of Effect of Pre-Processing Techniques in Solar Panel Fault Detection. **IEEE Access**, v. 11, p. 72848–72860, 2023.
- PERDOMO CC, KOZEN EA, SOBESTIANSKY J, SILVA AP, C. NI. Considerações sobre edificações para suínos. In: C. EMBRAPA; S. e Aves (Orgs.); Curso de Atualização sobre a Produção de Suínos. **Anais...**, 1985. Concórdia, SC.
- PERDOMO, C. C.; DE LIMA, G. J.; KOZEN, E. A.; SOBESTIANSKY, J. **Considerações sobre edificações para suínos**. Concórdia: EMBRAPA - CNPSA, 1985.
- PERIAUX, J.; TUOVINEN, T. Thirty Years of Progress in Single/Multi-disciplinary Design Optimization with Evolutionary Algorithms and Game Strategies in Aeronautics and Civil Engineering. . p.429–450, 2023.
- PINEDA, M.; BARÓN, M.; PÉREZ-BUENO, M.-L. Thermal Imaging for Plant Stress Detection and Phenotyping. **Remote Sensing**, v. 13, n. 1, p. 68, 2020.
- POONGODI, M.; HAMDY, M.; WANG, H. Image and audio caps: automated captioning of background sounds and images using deep learning. **Multimedia Systems**, v. 29, n. 5, p. 2951–2959, 2023.
- QIAO, Y.; GUO, Y.; HE, D. Cattle body detection based on YOLOv5-ASFF for precision livestock farming. **Computers and Electronics in Agriculture**, v. 204, p. 107579, 2023.
- QUEIROGA, E. M.; LOPES, J. L.; KAPPEL, K.; et al. A Learning Analytics Approach to Identify Students at Risk of Dropout: A Case Study with a Technical Distance Education Course. **Applied Sciences**, v. 10, n. 11, p. 3998, 2020.
- QURESHI, I.; YAN, J.; ABBAS, Q.; et al. Medical image segmentation using deep semantic-based methods: A review of techniques, applications and emerging trends. **Information Fusion**, v. 90, p. 316–352, 2023.
- RACEWICZ, P.; LUDWICZAK, A.; SKRZYPCZAK, E.; SKŁADANOWSKA-BARYZA, J.; BIESIADA, H.; NOWAK, T.; ŚLÓSZARZ, P. Welfare health and productivity in commercial pig herds. **Animals**, v. 11, n. 4, 2021.
- RAMIREZ, B. C.; HAYES, M. D.; CONDOTTA, I. C. F. S.; LEONARD, S. M. Impact of housing environment and management on pre-/post-weaning piglet productivity. **Journal of Animal Science**, v. 100, n. 6, 2022a.
- RAMIREZ, B. C.; HAYES, M. D.; CONDOTTA, I. C. F. S.; LEONARD, S. M. Impact of housing environment and management on pre-/post-weaning piglet productivity. **Journal of Animal Science**, v. 100, n. 6, 2022b.

RANJAN, R.; AVASTHI, V. Edge Detection Using Guided Sobel Image Filtering. **Wireless Personal Communications**, v. 132, n. 1, p. 651–677, 2023.

REIMERT, I.; WEBB, L. E.; VAN MARWIJK, M. A.; BOLHUIS, J. E. Review: Towards an integrated concept of animal welfare. **animal**, v. 17, p. 100838, 2023.

RELATÓRIO ANUAL. ABPA - Associação Brasileira de Proteína Animal. Relatório Anual 2023. Anuário 2023 da Suinocultura Industrial. . .

RIEKERT, M.; OPDERBECK, S.; WILD, A.; GALLMANN, E. Model selection for 24/7 pig position and posture detection by 2D camera imaging and deep learning. **Computers and Electronics in Agriculture**, v. 187, p. 106213, 2021.

ROBBERECHT, L.; DELATTRE, J.; MEIRE, M. Isthmus morphology influences debridement efficacy of activated irrigation: A laboratory study involving biofilm mimicking hydrogel removal and high-speed imaging. **International Endodontic Journal**, v. 56, n. 1, p. 118–127, 2023.

RODRIGUES, C. F.; BEZERRA, S. M. G.; CALÇADA, D. B. SISTEMAS COMPUTACIONAIS PARA AUXÍLIO NA CICATRIZAÇÃO DE FERIDAS: REVISÃO DE ESCOPO. **ESTIMA, Brazilian Journal of Enterostomal Therapy**, 2023.

RODRIGUES, L. A.; WELLINGTON, M. O.; GONZÁLEZ-VEGA, J. C.; et al. A longer adaptation period to a functional amino acid-supplemented diet improves growth performance and immune status of Salmonella Typhimurium-challenged pigs. **Journal of Animal Science**, v. 99, n. 5, p. 146, 2021.

ROY, S.; BHALLA, K.; PATEL, R. Mathematical analysis of histogram equalization techniques for medical image enhancement: a tutorial from the perspective of data loss. **Multimedia Tools and Applications**, v. 83, n. 5, p. 14363–14392, 2023.

RUIZ, R. D. B.; LORDSLEEM JUNIOR, A. C.; SOUSA NETO, A. F. DE; FERNANDES, B. J. T. Processamento digital de imagens para detecção automática de fissuras em revestimentos cerâmicos de edifícios. **Ambiente Construído**, v. 21, n. 1, p. 139–147, 2021.

SADEGHI, E.; KAPPERS, C.; CHIUMENTO, A.; DERKS, M.; HAVINGA, P. Improving piglets health and well-being: A review of piglets health indicators and related sensing technologies. **Smart Agricultural Technology**, v. 5, p. 100246, 2023.

SAIFULLAH, S.; DREŻEWSKI, R. Modified Histogram Equalization for Improved CNN Medical Image Segmentation. **Procedia Computer Science**, v. 225, p. 3021–3030, 2023.

LA SALANDRA, M.; COLACICCO, R.; DELLINO, P.; CAPOLONGO, D. An Effective Approach for Automatic River Features Extraction Using High-Resolution UAV Imagery. **Drones**, v. 7, n. 2, p. 70, 2023.

SAMPAIO, C. A. DE P.; CRISTANI, J.; DUBIELA, J. A.; BOFF, C. E.; OLIVEIRAM, M. A. DE. Avaliação do ambiente térmico em instalação para crescimento e terminação

de suínos utilizando os índices de conforto térmico nas condições tropicais. **Ciencia Rural**, v. 34, n. 3, p. 785–790, 2004.

SARKI, R.; AHMED, K.; WANG, H.; ZHANG, Y. Automatic Detection of Diabetic Eye Disease Through Deep Learning Using Fundus Images: A Survey. **IEEE Access**, v. 8, p. 151133–151149, 2020.

SARKI, R.; AHMED, K.; WANG, H.; ZHANG, Y.; WANG, K. Rede neural convolucional para classificação multiclasse de doenças oculares diabéticas. Transações endossadas pela EAI em sistemas de informação escaláveis. **Anais...**, 2022.

SARVAMANGALA, D. R.; KULKARNI, R. V. Convolutional neural networks in medical image understanding: a survey. **Evolutionary Intelligence**, v. 15, n. 1, p. 1–22, 2022.

SÁ, T. R. D.; FIGUEIREDO, C. M. S. Self-driving Vessels: YOLOv5 Approach for Water Surface Object Detection. , p. 31–40, 2022a.

SÁ, T. R. D.; FIGUEIREDO, C. M. S. Self-driving Vessels: YOLOv5 Approach for Water Surface Object Detection. Anais do XIV Simpósio Brasileiro de Computação Ubíqua e Pervasiva (SBCUP 2022). **Anais...** . p.31–40, 2022b. Sociedade Brasileira de Computação - SBC.

SECCHI, H. K.; CARRO, S. A. USO DE DEEP LEARNING APLICADO NO RECONHECIMENTO DE AÇÕES HUMANAS A PARTIR DE VÍDEOS EM ALTA RESOLUÇÃO VISANDO IDENTIFICAR MOVIMENTOS SUSPEITOS. **COLLOQUIUM EXACTARUM**, v. 14, n. 1, p. 67–75, 2022.

SEIDEL, D. S.; FIELD, T. C.; SCHINCKEL, A. P.; STWALLEY, C. S.; STWALLEY, R. M. Effects of temperature probe orientation on the Purdue hog cooling pad data acquisition. **Computers and Electronics in Agriculture**, v. 175, p. 105609, 2020.

SEREY, J.; ALFARO, M.; FUERTES, G.; et al. Pattern Recognition and Deep Learning Technologies, Enablers of Industry 4.0, and Their Role in Engineering Research. **Symmetry**, v. 15, n. 2, p. 535, 2023.

SEYEDI, S.; NAVIMIPOUR, N. J. A fault-tolerant image processor for executing the morphology operations based on a nanoscale technology. **Multimedia Tools and Applications**, v. 82, n. 2, p. 2489–2502, 2023.

SHAH, A.; BANGASH, J. I.; KHAN, A. W.; et al. Comparative analysis of median filter and its variants for removal of impulse noise from gray scale images. **Journal of King Saud University - Computer and Information Sciences**, v. 34, n. 3, p. 505–519, 2022.

SHAH, A.; SHAH, M.; PANDYA, A.; et al. A comprehensive study on skin cancer detection using artificial neural network (ANN) and convolutional neural network (CNN). **Clinical eHealth**, v. 6, p. 76–84, 2023.

SHAO, H.; PU, J.; MU, J. Pig-Posture Recognition Based on Computer Vision: Dataset and Exploration. **Animals**, v. 11, n. 5, p. 1295, 2021.

- SILVA, G. S. DA; MARTINS, A. M. Análise de comunalidades em artigos na área da visão computacional. **Caderno De Graduação - Ciências Exatas e Tecnológicas - UNIT - ALAGOAS**, v. 8, n. 1, p. 11–21, 2023.
- SILVA, T.; MINTZ, A.; OMENA, J. J.; et al. APIs de Visão Computacional: investigando mediações algorítmicas a partir de estudo de bancos de imagens. **Logos**, v. 27, n. 1, 2020.
- SILVA, W. A. DA; PANDORFI, H.; VIGODERIS, R. B.; et al. Exploratory inference of the ingestive behavior of pigs in the growth phase in an air-conditioned environment. **Livestock Science**, v. 272, p. 105232, 2023.
- SINDHOJ, E.; LINDAHL, C.; BARK, L. Potential alternatives to high-concentration carbon dioxide stunning of pigs at slaughter. **Animal**, v. 15, n. 3, p. 100164, 2021.
- SINGH, SUPREET; MITTAL, N.; NAYYAR, A.; SINGH, U.; SINGH, SIMRANDEEP. A hybrid transient search naked mole-rat optimizer for image segmentation using multilevel thresholding. **Expert Systems with Applications**, v. 213, p. 119021, 2023.
- SIVAMANI, S.; BASKAR, R.; CHANDRASEKARAN, A. P. Response surface optimization of acid pretreatment of cassava stem for bioethanol production. **Environmental Progress & Sustainable Energy**, v. 39, n. 2, 2020.
- SONG, N.; WANG, Y.; XIN, Z.; XIN, H.; LIU, T. Lightweight small target detection algorithm based on YOLOv5. In: P. Batista; Y. Zhang (Orgs.); Second International Conference on Applied Statistics, Computational Mathematics, and Software Engineering (ASCMSE 2023). **Anais...** . p.60, 2023. SPIE.
- SOUSA, S. L. G. DE; REIS, R. C. S.; OLIVEIRA, R. V. DE; et al. Bem-estar animal e os sistemas de produção no século XXI. **Pubvet**, v. 17, n. 2, p. 1–9, 2023.
- SOUZA, B. J.; STEFENON, S. F.; SINGH, G.; FREIRE, R. Z. Hybrid-YOLO for classification of insulators defects in transmission lines based on UAV. **International Journal of Electrical Power & Energy Systems**, v. 148, p. 108982, 2023.
- SOUZA, H. C. DE; FEH, L. C. F. DE A.; TAVARES, M.; TRINDADE, J. A. DE S.; MAGNAGO, B. S. Custos de produção de suínos: estudo nos principais estados produtores do Brasil. **Revista da Micro e Pequena Empresa**, p. 72–87, 2023.
- SOUZA, M. V.; GUIMAÃES, C. R. R.; PEREIRA, E. C. X. P. MANEJO SANITÁRIO E BEM-ESTAR NA CRIAÇÃO DE LEITÕES. **Revista Multidisciplinar do Nordeste Mineiro**, v. 12, n. 1, 2023.
- SOUZA, P. **Suínos e climas quentes: como promover o bem-estar aos animais? Conforto térmico e bem estar na suinocultura**. Lavras: UFLA ed. 2004.
- STEFENON, S. F.; SINGH, G.; SOUZA, B. J.; FREIRE, R. Z.; YOW, K. Optimized hybrid YOLOu-Quasi-ProtoPNet for insulators classification. **IET Generation, Transmission & Distribution**, v. 17, n. 15, p. 3501–3511, 2023.
- TAVARES, L. A.; MEIRA, M. C.; AMARAL, S. F. DO. Inteligência Artificial na Educação: Survey. **Brazilian Journal of Development**, v. 6, n. 7, p. 48699–48714, 2020.

- THAKUR, A.; VENU, S.; GURUSAMY, M. An extensive review on agricultural robots with a focus on their perception systems. **Computers and Electronics in Agriculture**, v. 212, p. 108146, 2023.
- TONG, C.; YANG, X.; HUANG, Q.; QIAN, F. NGIoU Loss: Generalized Intersection over Union Loss Based on a New Bounding Box Regression. **Applied Sciences**, v. 12, n. 24, p. 12785, 2022.
- TSAI, H.; LU, N.; LIU, K.; LIN, C.; WANG, J. Cascading AB-YOLOv5 and PB-YOLOv5 for rib fracture detection in frontal and oblique chest X-ray images. **IET Computer Vision**, v. 17, n. 7, p. 750–762, 2023.
- VANZAN, A.; FIM, G.; WELTER, G.; GRIEBLER, D. Aceleração da Classificação de Lavouras de Milho com MPI e Estratégias de Paralelismo. Anais da XXI Escola Regional de Alto Desempenho da Região Sul (ERAD RS 2021). **Anais...** . p.49–52, 2021. Sociedade Brasileira de Computação - SBC.
- VAZ, G. D. R.; GODOY, P. C.; DE SOUZA, R. T.; et al. Estimativa de bem-estar de suínos alojados em maternidades livres de gaiolas a partir da utilização de decibelímetros digitais. **Zootecnia: pesquisa e práticas contemporâneas**, v. 3, p. 275, 2022.
- VEDA SAI ROCHISHNA, E.; V N S M P GANESH HARI PRASAD RAO, V.; BHARGAV, G.; SATHYALAKSHMI, S. Lossless Image Compression Using Machine Learning. . p.113–125, 2023.
- VENTURA, S.; LUNA, M. J.; MOYANO, M. J. **Genetic Algorithms**. IntechOpen, 2022.
- VICTORIA, A. H.; MARAGATHAM, G. Automatic tuning of hyperparameters using Bayesian optimization. **Evolving Systems**, v. 12, n. 1, p. 217–223, 2021.
- VILAS-BOAS, J.; KLERKX, L.; LIE, R. Facilitating international animal welfare standards implementation in national contexts: The role of intermediaries in Brazilian pig production. **Journal of Rural Studies**, v. 90, p. 53–64, 2022.
- VOOGT, A. M.; URSINUS, W. W.; SIJM, D. T. H. M.; BONGERS, J. H. From the Five Freedoms to a more holistic perspective on animal welfare in the Dutch Animals Act. **Frontiers in Animal Science**, v. 4, 2023.
- WAHEED, S. R.; RAHIM, M. S. M.; SUAIB, N. M.; SALIM, A. A. CNN deep learning-based image to vector depiction. **Multimedia Tools and Applications**, v. 82, n. 13, p. 20283–20302, 2023.
- WANG, J.; BEI, J.; SONG, H.; ZHANG, H.; ZHANG, P. A whale optimization algorithm with combined mutation and removing similarity for global optimization and multilevel thresholding image segmentation. **Applied Soft Computing**, v. 137, p. 110130, 2023.
- WANG, M.; LI, X.; LARSEN, M. L. V.; et al. A computer vision-based approach for respiration rate monitoring of group housed pigs. **Computers and Electronics in Agriculture**, v. 210, p. 107899, 2023a.
- WANG, M.; LI, X.; LARSEN, M. L. V.; et al. A computer vision-based approach for respiration rate monitoring of group housed pigs. **Computers and Electronics in Agriculture**, v. 210, p. 107899, 2023b.

WANG, Q.; MA, Y.; ZHAO, K.; TIAN, Y. A Comprehensive Survey of Loss Functions in Machine Learning. **Annals of Data Science**, v. 9, n. 2, p. 187–212, 2022.

WANG, X.; WU, Z.; JIA, M.; et al. Lightweight SM-YOLOv5 Tomato Fruit Detection Algorithm for Plant Factory. **Sensors**, v. 23, n. 6, p. 3336, 2023.

WANG, Y.; MA, X.; CHEN, Z.; et al. Symmetric Cross Entropy for Robust Learning with Noisy Labels. IEEE/CVF International Conference on Computer Vision (ICCV). **Anais...** . p.322–330, 2019. Seoul. Korea.

WANG, Y.; SUN, G.; SENG, X.; et al. Deep learning method for rapidly estimating pig body size. **Animal Production Science**, v. 63, n. 9, p. 909–923, 2023.

WAN, M.; CHEN, X.; ZHAN, T.; et al. Low-rank 2D local discriminant graph embedding for robust image feature extraction. **Pattern Recognition**, v. 133, p. 109034, 2023.

WEIMER, S. L.; WIDEMAN, R. F.; SCANES, C. G.; et al. Broiler stress responses to light intensity, flooring type, and leg weakness as assessed by heterophil-to-lymphocyte ratios, serum corticosterone, infrared thermography, and latency to lie. **Poultry Science**, v. 99, n. 7, p. 3301–3311, 2020.

WITTE, J.-H.; MARX GÓMEZ, J. Introducing a new Workflow for Pig Posture Classification based on a combination of YOLO and EfficientNet. , 2022.

WU, D.; WANG, C.; WU, Y.; WANG, Q.-C.; HUANG, D.-S. Attention Deep Model With Multi-Scale Deep Supervision for Person Re-Identification. **IEEE Transactions on Emerging Topics in Computational Intelligence**, v. 5, n. 1, p. 70–78, 2021.

WU, Q.; CASTLEMAN, K. R. Image Segmentation. **Microscope Image Processing**. p.119–152, 2023. Elsevier.

XIONG, Q.; ZHANG, X.; WANG, X.; QIAO, N.; SHEN, J. Robust Iris-Localization Algorithm in Non-Cooperative Environments Based on the Improved YOLO v4 Model. **Sensors**, v. 22, n. 24, p. 9913, 2022.

XU, J.; ZHOU, S.; XU, A.; YE, J.; ZHAO, A. Automatic scoring of postures in grouped pigs using depth image and CNN-SVM. **Computers and Electronics in Agriculture**, v. 194, p. 106746, 2022.

XU, Q.; ZHU, Z.; GE, H.; ZHANG, Z.; ZANG, X. Effective Face Detector Based on YOLOv5 and Superresolution Reconstruction. **Computational and Mathematical Methods in Medicine**, v. 2021, p. 1–9, 2021.

XU, W.; LI, B.; DU, Y.; DONG, S. Study on Facial Recognition Method Based on YOLOv5. **Journal of Physics: Conference Series**, v. 2560, n. 1, p. 012020, 2023.

YANG, R. Method of insulator defect detection based on the improved YOLOv5s. In: L. Yang; W. Tan (Orgs.); Sixth International Conference on Advanced Electronic Materials, Computers, and Software Engineering (AEMCSE 2023). **Anais...** . p.98, 2023. SPIE.

YANG, R.; LI, W.; SHANG, X.; ZHU, D.; MAN, X. KPE-YOLOv5: An Improved Small Target Detection Algorithm Based on YOLOv5. **Electronics**, v. 12, n. 4, p. 817, 2023.

YANG, Y.; LI, Y.; LI, K.; et al. DECCO: Deep-learning enabled coverage and capacity optimization for massive MIMO systems. **IEEE**, v. 6, p. 23361–23371, 2018.

YAN, P.; YAMAMOTO, S. Relationships between thermoregulatory responses and heat loss in piglets. **Animal Science Journal**, v. 71, n. 10, 2000.

YOUSRY, N.; KHATTAB, A. Accurate Real-Time Face Mask Detection Framework Using YOLOv5. 2022 IEEE International Conference on Design & Test of Integrated Micro & Nano-Systems (DTS). **Anais...** . p.01–06, 2022. IEEE.

YUAN, F.; ZHANG, Z.; FANG, Z. An effective CNN and Transformer complementary network for medical image segmentation. **Pattern Recognition**, v. 136, p. 109228, 2023.

YUAN, Y.; LIN, L.; ZHOU, Z.-G.; JIANG, H.; LIU, Q. Bridging optical and SAR satellite image time series via contrastive feature extraction for crop classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 195, p. 222–232, 2023.

YU, Y.; WANG, C.; FU, Q.; et al. Techniques and Challenges of Image Segmentation: A Review. **Electronics**, v. 12, n. 5, p. 1199, 2023.

ZHANG, J.; CHEN, Z.; YAN, G.; WANG, Y.; HU, B. Faster and Lightweight: An Improved YOLOv5 Object Detector for Remote Sensing Images. **Remote Sensing**, v. 15, n. 20, p. 4974, 2023.

ZHANG, R.; WEN, C. SOD-YOLO: A Small Target Defect Detection Algorithm for Wind Turbine Blades Based on Improved YOLOv5. **Advanced Theory and Simulations**, v. 5, n. 7, 2022.

ZHANG, S.; ZHANG, C. Modified U-Net for plant diseased leaf image segmentation. **Computers and Electronics in Agriculture**, v. 204, p. 107511, 2023.

ZHANG, W.; XU, Y.; BAI, R.; LI, L. Animal Pose Estimation Algorithm Based on the Lightweight Stacked Hourglass Network. **IEEE Access**, v. 11, p. 5314–5327, 2023.

ZHANG, X.; FAN, H.; ZHU, H.; et al. Improvement of YOLOV5 Model Based on the Structure of Multiscale Domain Adaptive Network for Crowdscape. 2021 IEEE 7th International Conference on Cloud Computing and Intelligent Systems (CCIS). **Anais...** . p.171–175, 2021. IEEE.

ZHANG, Y.; GUO, Z.; WU, J.; et al. Real-Time Vehicle Detection Based on Improved YOLO v5. **Sustainability**, v. 14, n. 19, p. 12274, 2022.

ZHAO, Y.; KANG, Z.; CHEN, L.; et al. Quality classification of kiwifruit under different storage conditions based on deep learning and hyperspectral imaging technology. **Journal of Food Measurement and Characterization**, v. 17, n. 1, p. 289–305, 2023.

ZHENG, L.; ZHOU, J.; CHEN, C.; et al. ASFGNN: Automated separated-federated graph neural network. **Peer-to-Peer Networking and Applications**, v. 14, n. 3, p. 1692–1704, 2021.

ZHENG, S.; ZHOU, C.; JIANG, X.; HUANG, J.; XU, D. Progress on Infrared Imaging Technology in Animal Production: A Review. **Sensors**, v. 22, n. 3, p. 705, 2022.

ZHENG, W.; LIU, X.; YIN, L. Research on image classification method based on improved multi-scale relational network. **PeerJ Computer Science**, v. 7, p. e613, 2021.

ZHOU, S.; CHENG, Y.; TAMURA, S. Automated lung segmentation and smoothing techniques for inclusion of juxtapleural nodules and pulmonary vessels on chest CT images. **Biomedical Signal Processing and Control**, v. 13, p. 62–70, 2014.

ZHOU, T.; LI, L.; BREDELL, G.; et al. Volumetric memory network for interactive medical image segmentation. **Medical Image Analysis**, v. 83, p. 102599, 2023.

ZHOU, Z. Detection and Counting Method of Pigs Based on YOLOV5_Plus: A Combination of YOLOV5 and Attention Mechanism. **Mathematical Problems in Engineering**, v. 2022, p. 1–16, 2022.

ZHOU, Z.; HUBER, N. R.; INOUE, A.; MCCOLLOUGH, C. H.; YU, L. Multislice input for 2D and 3D residual convolutional neural network noise reduction in CT. **Journal of Medical Imaging**, v. 10, n. 01, 2023.

CAPÍTULO II

**TÉCNICAS COMPUTACIONAIS PARA ANÁLISE DE IMAGENS TÉRMICAS
DE SUÍNOS E CARACTERIZAÇÃO DO ESTRESSE POR CALOR NO
AMBIENTE DE CRIAÇÃO**

Técnicas computacionais para análise de imagens térmicas de suínos e caracterização do estresse por calor no ambiente de criação

Resumo

O estresse por calor destaca-se como um dos principais elementos vinculados às preocupações relacionadas ao conforto térmico animal. Esta pesquisa foi conduzida com o objetivo de desenvolver uma metodologia sequencial para extração de características automáticas de imagens térmicas e a classificação de estresse térmico em suínos por meio de aprendizado de máquina. Foram obtidas imagens infravermelhas, com auxílio de um termovisor FLIR E60, de 18 suínos alojados em baias climatizadas e não climatizadas. A análise de imagens consistiu em seu pré-processamento por meio da conversão da imagem térmica para o espaço de cor matiz, saturação e valor (HSV), seguido da segmentação por cor, para isolar a região de interesse e extrair as características de variação da temperatura de superfície do corpo do animal a partir de algoritmo desenvolvido para conversão dos pixels de cores RGB em temperaturas com base na escala de cor da câmera FLIR (arco-íris) e em um vetor de temperatura correspondentes a paleta, seguido do reconhecimento do padrão de conforto. Os resultados indicaram que o método de segmentação automatizada, pela cor foi capaz de identificar a região de interesse com precisão média de 88% e a extração da temperatura diferiu do programa Therma Cam em 0,82°C. Utilizando Máquina de Suporte de Vetor (SVM) a pesquisa alcançou uma taxa de precisão de 80% na classificação automática de suínos em conforto e desconforto térmico, com uma acurácia de 91%, indicando que a proposta tem potencial para monitorar e avaliar o conforto térmico de suínos de forma eficaz.

Palavras-chave: Aprendizado de máquina. Bem-estar animal. Monitoramento térmico. Termografia infravermelho.

2.1 Introdução

O estresse térmico destaca-se como um dos principais elementos vinculados às preocupações relacionadas ao bem-estar animal (MACHADO et al., 2023). De acordo com Alves et al. (2023) elevadas temperaturas do ambiente de criação induzem estresse térmico nos animais, resultando em efeitos adversos que afetam suas respostas fisiológicas, comportamentais e a ingestão de alimentos. Cai et al. (2023) argumentam que a temperatura corporal dos animais é suscetível aos efeitos adversos de elementos

meteorológicos, como temperatura do ar, umidade relativa do ar e radiação solar, que podem ocasionar variações na temperatura corporal do animal.

Em suínos, o estresse térmico decorre de um desequilíbrio na regulação térmica, em que o animal gera mais calor do que consegue dissipar para o ambiente. Isso pode levar a reduções no consumo de ração, no crescimento, na eficiência alimentar e na taxa reprodutiva (BROWN-BRANDL et al., 2023a).

As respostas fisiológicas, como a frequência respiratória e a temperatura corporal interna, constituem indicadores de saúde, conforto térmico e, por conseguinte, eficiência produtiva dos animais. Contudo, a coleta dessas variáveis é tradicionalmente invasiva, manual e visual, o que a torna o processo trabalhoso e estressante para os animais e atualmente não atende mais a pecuária moderna (RODRIGUES et al., 2023).

A temperatura superficial dos suínos também é um indicador do seu estado de conforto térmico (TITTO et al., 2023). O monitoramento da temperatura corporal dos animais permite identificar os indivíduos em estresse térmico ou infectados, contribuindo para a prevenção mitigatória do estresse, por meio de sistemas de climatização ou da propagação de doenças pelo isolamento de suínos afetados (WANG e ZHEN et al., 2023).

A variação da temperatura da superfície corporal dos animais se manifesta de forma direta, a partir da vasodilatação periférica nos tecidos ativos, como resposta a alta temperatura do ar. Alterações em decorrência de processos infecciosos, também impactam a temperatura dos tecidos internos, provocando variações no fluxo sanguíneo e liberando energia na forma de radiação infravermelha. Essas alterações se evidenciam por meio de uma distribuição desigual de temperatura entre as distintas regiões corporais (COŞKUN et al., 2023). Por esse motivo, segundo Cai et al. (2023) é possível medir a temperatura da superfície corporal utilizando uma câmera térmica sensível ao infravermelho.

Diante do aumento da temperatura ambiental, os suínos ajustam suas temperaturas corporais mediante a transferência de energia do corpo para o ambiente por meio sensíveis (condução, convecção e radiação) e latente (evaporação), com a ativação de mecanismos fisiológicos de sudorese e taquipneia. Além disso, expandem os vasos sanguíneos superficiais para facilitar a perda de calor, sendo que o efeito da vasodilatação auxilia na dissipação de energia por irradiação, com aumento da temperatura da superfície da pele, capturada pela termografia por infravermelho (RODRIGUES et al., 2023).

A imagem térmica representa um método não invasivo e não destrutivo para a medição da temperatura de um objeto. Esse processo se utiliza da irradiação no espectro

do infravermelho emitido pelo objeto para formar um perfil visual da temperatura na cena capturada, conforme discutido por Wilson et al. (2023). No interior do termovisor infravermelho encontra-se um sensor de temperatura infravermelho sem contato, capaz de detectar a radiação infravermelha emitida pela superfície do objeto, conforme mencionado por Godyń e Herbut (2018).

Os dados de temperatura da superfície do objeto são convertidos em uma imagem em escala de cinza ou em uma imagem colorida por meio do sistema de processamento de sinal interno após o termovisor infravermelho captar a radiação infravermelha. Quanto maior a intensidade da radiação infravermelha proveniente do objeto analisado, maior será o nível de cinza ou a intensidade de cor na imagem térmica, como observado no estudo de He; Zhang; Li e Gan (2020).

O emprego crescente dessas tecnologias não invasivas tem se destacado como alternativa para o monitoramento da temperatura corporal dos animais (XIONG et al., 2023). A termografia infravermelha (IRT) tende a ser uma tecnologia promissora não invasiva e tem o potencial de reduzir a resposta de estresse nos animais associada à medição da temperatura por contato, como a medição da temperatura retal, que, por sua vez, pode ocasionar a transferência de bactérias e outros agentes patogênicos para o animal. Ela está sendo progressivamente incorporada tanto em pesquisas quanto em aplicações práticas para a medição da temperatura em animais (CAI et al., 2023; TUCKER et al., 2023).

A IRT não apenas serve para automatizar o monitoramento da temperatura superficial dos suínos, mas também pode ser utilizada para extrair a forma corporal dos animais por meio da segmentação de seu contorno, possibilitando a avaliação das condições de estresse na região de interesse via técnicas de visão computacional (WANG et al., 2023).

Na visão computacional, a tecnologia de segmentação de imagens desempenha um papel importante em sistemas de diagnóstico, auxiliados por computador, para identificar com precisão a área de interesse (SINGH et al., 2023). Cabe destacar que as técnicas de detecção utilizando IRT podem ser aprimoradas por meio da aplicação de algoritmos de pré e pós-processamento nos dados termográficos para eliminar interferências indesejadas, assegurando diagnósticos precisos e confiáveis (LIU et al., 2023).

Rodrigues et al. (2023) desenvolveram um método chamado Assinatura Térmica, para extrair características dos dados obtidos por IRT e empregá-las como atributos de

entrada em modelos baseados em aprendizado de máquina para avaliar o estresse térmico em bezerros e alcançaram uma precisão de 83,29% na classificação térmica de conforto, alerta, perigo e emergência utilizando a temperatura da região ocular obtida da imagem térmica. McManus et al. (2022) recomendam o uso da IRT como ferramenta de auxílio para reconhecimento de estados infecciosos em animais de produção. Devido à sua natureza não invasiva, Whittaker et al. (2023) argumentam que a IRT emerge como uma alternativa eficaz na avaliação da dor, sendo empregada para detectar processos agudos em estados inflamatórios, como a osteoartrite, e durante procedimentos cirúrgicos rotineiros, tais como castração, corte de cauda e desbrotação, nos quais nem sempre são administradas drogas analgésicas aos animais.

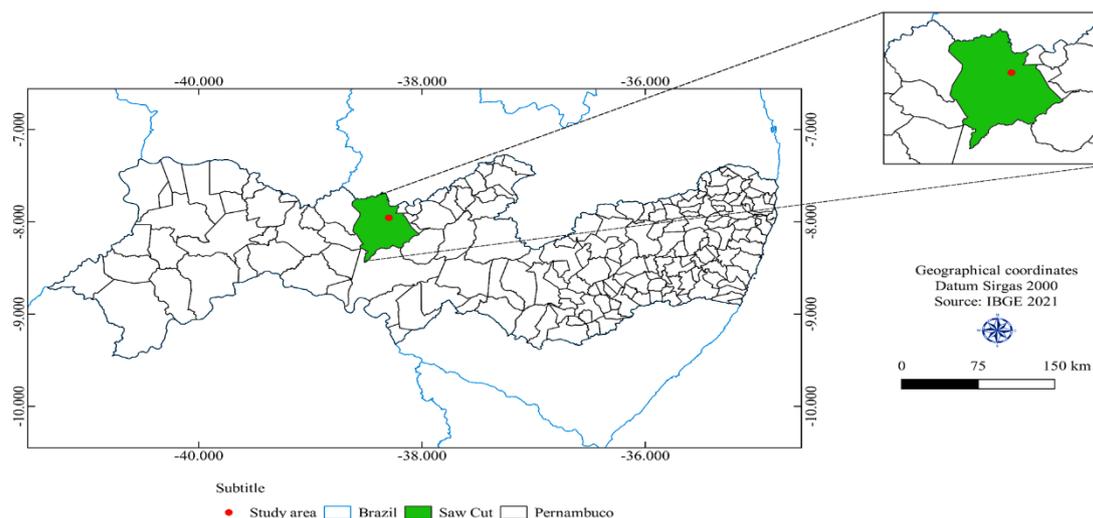
Na análise de imagens térmicas de suínos, um dos objetivos fundamentais é prever o conforto térmico dos animais. Isso envolve a identificação de padrões de temperatura que indicam se os suínos estão em condições de conforto ou estresse térmico. Essa predição é importante para garantir o bem-estar e o desempenho adequado dos animais na produção animal, pois, o conforto térmico influencia diretamente sua saúde e produtividade. Neste contexto, este estudo foi conduzido com o objetivo de desenvolver uma metodologia sequencial para extração de características automáticas de imagens térmicas e classificação de estresse térmico de suínos por meio do aprendizado de máquina.

2.2 Material e métodos

2.2.1 Localização e caracterização da área de estudo

O monitoramento foi realizado no biotério de pesquisa animal localizado na Unidade Acadêmica de Serra Talhada (UAST) da Universidade Federal Rural de Pernambuco (UFRPE) com suínos nas fases de crescimento e terminação (Figura 8).

Figura 8. Localização da área de estudo.



O clima do local de estudo segundo Reis et al. (2023) é do tipo BSwh. Esse tipo de clima é denominado semiárido, quente e seco. Diniz e Ataíde (2023) acrescentam descrevendo que a média anual de precipitação é de 642 mm e as temperaturas variam de 20,1°C a 32,9°C e, a umidade relativa média do ar é de 63%.

2.2.2 Coleta de dados

A coleta de dados ocorreu ao longo de 92 dias, no período compreendido entre agosto e dezembro de 2017. O experimento foi conduzido em conformidade com as diretrizes éticas e recebeu aprovação da Comissão de Ética no Uso de Animais da Universidade Federal Rural de Pernambuco (CEUA/UFRPE). O protocolo de aprovação utilizado foi o nº 23082.021090/2016-81, garantindo que todas as medidas necessárias para o bem-estar e cuidado dos animais fossem seguidas durante a pesquisa.

Foram utilizados 18 suínos, incluindo machos e fêmeas, distribuídos em grupo de 3 entre as baias. Os animais foram selecionados a partir de um grupo disponível no biotério de experimentação da universidade, da linhagem comercial $\frac{3}{4}$ Duroc e $\frac{1}{4}$ Pietrain.

Foram utilizadas 6 baias, três com um sistema de climatização, equipadas com sistema de resfriamento adiabático evaporativo e três sem nenhum sistema de climatização, permitindo a análise dos animais em condições de ventilação natural. Os climatizadores utilizados nas baias possuíam vazão de 3 L/h, com motores independentes e hélice girando a uma velocidade de 1.750 RPM e disco central a 3.450 RPM.

2.2.2.1. Registro das imagens térmicas

As imagens foram obtidas por meio de um termovisor infravermelho da marca FLIR modelo E60. O termovisor apresenta escala de temperatura com sensibilidade térmica variando de -20 a 120°C, com precisão de leitura de $\pm 2^\circ\text{C}$, resolução IR de 320 x 240 pixels e o software utilizado para descarregar as imagens foi o *FLIR Tools* que apresentava compatibilidade com o equipamento.

O registro das imagens foi realizado sob uma distância de um 1 m entre a câmera termográfica e o animal. Essa distância foi suficiente para enquadrar todo o corpo do animal. Os registros foram feitos semanalmente às 08:00, 12:00 e 16:00h. Foram adquiridas 486 imagens, no entanto, optou-se por selecionar aquelas em que era possível distinguir os animais. Isso resultou em um total de 226 imagens térmicas, sendo 113 do ambiente climatizado e 113 do ambiente não climatizado com dimensões de 320 x 240 pixels, que foram posteriormente exportadas para o formato ".jpg".

As imagens foram ajustas com base nas condições atmosféricas locais, considerando a temperatura e umidade relativa do ambiente. Além disso, a emissividade também foi corrigida para 0,98 que segundo Tucker et al. (2023) é a ideal para tecidos biológicos e de acordo com Wang e Zhen et al. (2023) é utilizada em mais de 60% das pesquisas. As correções foram feitas de forma manual no software *FLIR Tools*.

2.2.2.2 Registro das variáveis ambientais

Foram registradas a temperatura do ar (T_{bs} , em $^\circ\text{C}$), a umidade relativa do ar (UR, em %), a temperatura de globo negro (T_{g} , em $^\circ\text{C}$) e a velocidade do vento (V_{v} , em m/s) durante os 92 dias de monitoramento. Os registros de temperatura do ar, umidade relativa do ar e temperatura do globo negro foram realizados utilizando um *datalogger* modelo U12-012 (Onset Computer Corporation Bourne, MA, EUA), da marca HOBO®, durante o dia e a noite. O posicionamento do instrumento seguiu as recomendações de Barbosa et al. (2007), que sugerem que os equipamentos sejam instalados preferencialmente na região central do galpão.

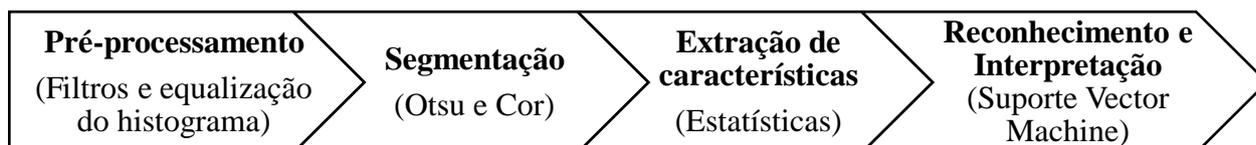
A coleta de dados referente à velocidade do vento (V_{v} , em m/s) foi realizada utilizando um termo-anemômetro digital, modelo TAFR-180, com escala de 0,1 a 20,0 m/s e resolução de 0,1 m/s, a uma distância de 1,50 m do solo.

Essas variáveis foram coletadas dentro das baias, por meio do *datalogger* e no ambiente externo, utilizando um abrigo meteorológico. Ambos os equipamentos foram posicionados a uma altura de 1,50 m, visando obter informações representativas das variações entre os tratamentos.

2.2.3 Ferramenta utilizada

Este estudo propôs um método de extração automático de características e classificação de imagens térmicas em suínos. O método foi desenvolvido em quatro etapas: pré-processamento, segmentação de imagem, extração de características e reconhecimento e interpretação do padrão, baseado na proposta de Wang e Zhen et al. (2023). O algoritmo proposto está apresentado no fluxograma (Figura 9).

Figura 9. Fluxograma do algoritmo proposto.



2.2.3.1 Pré-processamento

As etapas de pré-processamento das imagens foram realizadas no intuito de remover ruídos que se referem a interferências indesejadas ou distorções nas imagens que podem ser causadas por vários fatores, como falhas no equipamento de aquisição de imagens, condições ambientais adversas, ou imperfeições nos processos de transmissão ou armazenamento, provenientes da etapa de aquisição da imagem. Tais etapas constituíram-se da conversão da imagem original para o espaço de cores HSV (Matiz, Saturação e Valor). O espaço de cores HSV separa a cor, a saturação e o valor de uma imagem. O canal H (matiz) da imagem HSV foi isolado para preservar as informações relacionadas à matiz (cor) e foram aplicados filtros para suavizar a imagem e remover ruídos, aprimorando a qualidade e a precisão das informações.

Foi aplicado para fins de análise, o filtro mediano e o bilateral da biblioteca (*Open Source Computer Vision*) de código aberto, desenvolvida pela *Intel Corporation*. A avaliação do desempenho dos filtros ocorreu por meio da aplicação da Medida do Índice de Similaridade Estrutural (MISE), ou no inglês *Structural Similarity Index Measure (SSIM)* que é uma métrica usada para avaliar a qualidade de uma imagem, incluindo a preservação de detalhes contraste e nitidez.

O SSIM varia de -1 a 1. Um valor de +1 indica que as duas imagens a segmentada automática e a segmentada de referência são verdadeiramente muito semelhantes, enquanto um valor de -1 indica que as imagens são distintas (SINGH et al., 2023). Dessa forma, quanto maior o valor do SSIM, mais similar a imagem é a de referência ou a

original. Este procedimento seguiu a metodologia adotada na pesquisa de Kalaiyarasi et al. (2023) a qual analisaram os resultados do filtro mediano em imagens médicas por meio do SSIM. Após a análise do SSIM, o tipo de filtro com o valor mais elevado foi selecionado.

Para melhorar o contraste foi aplicado a equalização de histograma, onde um histograma representa a distribuição de intensidades de pixels em uma imagem, e a equalização envolve a redistribuição dessas intensidades para alcançar uma distribuição mais uniforme. Esse processo é particularmente útil para realçar detalhes em áreas de sombras e realçar características importantes. Ao calcular a função de distribuição acumulativa, a equalização do histograma transforma a imagem, aumentando a nitidez e melhorando o contraste de maneira global.

2.2.3.2 Segmentação

A segmentação da região de interesse foi realizada por dois métodos. O método de segmentação proposto por Otsu (1979) e o método de segmentação por cor. No método de Otsu as imagens filtradas foram transformadas em escala de cinza, apresentando intensidades que variam de 0 a 255, em que foi aplicada a técnica de limiarização, onde um limiar da imagem foi determinado de forma automática com base no histograma para eliminar o fundo das imagens.

Foram empregadas técnicas de erosão e dilatação para ajustes no resultado da segmentação da imagem, em que se utilizou um operador morfológico de fechamento com um elemento estruturante da área de interesse (GONZALEZ e WOODS, 2007). Tais procedimentos foram desenvolvidos conforme proposta de Bareli (2019). A limiarização resultante foi invertida para que a região de interesse aparecesse branco (255) e o fundo em preto (0). Esse processo garantiu que apenas os pixels associados aos animais segmentados permanecessem visíveis, enquanto os pixels do fundo foram suprimidos, atribuindo-lhes o valor zero.

Em seguida, os contornos dos animais binarizados foram identificados na imagem com base na aplicação do algoritmo *findContours* do OpenCV e foram desenhados sobre a imagem em escala de cinza.

Posterior a essas etapas procedeu-se a geração de uma máscara em branco e a adição de uma binarização com limiar encontrado de forma automática de valor igual a 25, onde foram adicionados os contornos filtrados, realçando as áreas de interesse.

A técnica de segmentação por cor permitiu separar os suínos representados pela cor dos pixels mais quentes da imagem, utilizando o espaço de cor HSV (Hue, Saturation, Value) (BARELI, 2019). Sendo assim, o espaço HSV reuniu as informações referentes à cor (matiz) em um único canal, para geração de vetores contendo os valores referentes ao limite inferior (cores mais escuras) e superior (cor branca).

Para a segmentação por cor foi adotado a proposta de Bareli (2019) que considera a segmentação com base no espaço HSV. A Tabela 5 apresenta os intervalos para as cores amarelo, azul, verde e vermelho. Por exemplo, o intervalo do amarelo abrange a escala de matiz (H) de 10 a 50, representando a faixa característica dessa cor. Os valores S são utilizados para limitar a saturação, variando de 100 a 255, enquanto o valor V é a luminância e define a faixa de brilho, variando de 100 a 255.

Tabela 5. Valores inferiores e superiores do espaço HSV.

Cor	Limite inferior	Limite superior
Amarelo	10, 100, 100	50, 255, 255
Azul	100, 100, 100	140, 255, 255
Verde	40, 100, 100	80, 255, 255
Vermelho	160, 100, 100	200, 255, 255

Fonte: Bareli (2019).

Após a conversão para o espaço de cores HSV, foram extraídas máscaras, cada uma projetada para englobar uma faixa de cores específica, com exceção das tonalidades frias, conforme a escala das imagens, que incluiu a anotação manual dos valores mínimo e máximo de cada uma, proporcionando a base para a geração da faixa de temperatura e a paleta de cores do *software ThermaCam* (Tabela 6).

Tabela 6. Intensidade de cor e temperatura associada.

Intensidade da cor	Temperatura correspondente (°C)
(15, 0, 15)	23.1
(31, 0, 31)	23.2
(47, 0, 47)	23.4
(63, 0, 63)	23.5

Fonte: *Software ThermaCam*, 2022.

Esse processo teve como objetivo identificar as cores dos pixels mais quentes na imagem. A etapa de segmentação foi realizada com a exclusão de todos os pixels que não pertenciam à região de interesse, pois dessa forma todos os pixels frios da imagem foram zerados.

Posteriormente, todas as máscaras individuais foram unificadas, destacando assim, as áreas de interesse na imagem. Além disso, foi gerada uma máscara suplementar para os contornos dos animais e os tratamentos das possíveis falhas, conforme procedimento já descrito anteriormente.

Para validar um método de segmentação de imagens é necessário comparar as imagens segmentadas de forma automática com imagens segmentadas de forma manual (referência). Nesse sentido, foram elaboradas segmentações de referência específicas para este estudo, as quais foram estabelecidas como padrão. Para realizar as segmentações de referência, as imagens foram anotadas manualmente na Plataforma Online VGG *Image Annotator* (Versão 2.0.11) delimitando o contorno da região de interesse de forma livre e com isso foi obtido um arquivo com as coordenadas de bordas dos animais. Utilizando a biblioteca *OpenCV* e a linguagem *Python* na *IDE Pycharm*, as máscaras foram geradas e convertidas em imagens binárias. A região de interesse e o fundo da imagem foram identificados através das cores branco e preto, correspondendo a valores de pixels de 255 e 0, respectivamente. Posteriormente foi realizado um recorte na imagem utilizando a máscara de contorno, usando operadores binários do *OpenCV* (*CV2.bitwise_and*).

Para avaliar os resultados da segmentação de suínos nas imagens termográficas foram introduzidas métricas de avaliação baseadas no índice de similaridade de Jaccard (Equação 1), no coeficiente de Dice (Equação 2) e na precisão (Equação 3) propostas por Zhang et al. (2023).

$$\text{Índice de Jaccard} = \frac{TP}{TP+TN+FN} \quad (1)$$

$$\text{Coeficiente de Dice} = \frac{2*TP}{2*TP+FP+FN} \quad (2)$$

$$\text{Precisão (P)} = \frac{TP}{TP+FP} \quad (3)$$

O Índice de Jaccard é uma métrica que quantifica a similaridade entre dois conjuntos e na segmentação de imagens, ele é usado para avaliar o quão bem a imagem segmentada automaticamente se sobrepõe à imagem segmentada manualmente. Quanto mais próximo o valor do Índice de Jaccard estiver de 1, maior a sobreposição entre as duas imagens e mais precisa é a segmentação.

O Coeficiente de Dice também é uma métrica de similaridade usada para avaliar a sobreposição ou a concordância entre dois conjuntos. Varia de 0 a 1, onde 0 indica nenhuma sobreposição e 1 indica uma sobreposição de concordância total. Quanto mais

próximo de 1, melhor o desempenho do algoritmo em relação à segmentação de referência.

A precisão foi calculada considerando a proporção de pixels identificados pelo algoritmo em comparação com o número de pixels encontrados na segmentação manual. Precisão mais próxima de 1, indicam a eficácia do método de segmentação na identificação desses elementos, enquanto precisões mais distantes de 1, sinalizam um desempenho inferior na segmentação.

As métricas foram avaliadas considerando os verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN). Os VP correspondem aos pixels dos animais que foram segmentados de forma precisa pelo método de segmentação, em conformidade com a segmentação manual. Já os VN são os pixels que representam o fundo da imagem.

Os FP incluem os pixels que foram incorretamente incluídos na segmentação como parte do suíno, porém, não são, contrariando a segmentação manual. Trata-se dos pixels do fundo da imagem que foram erroneamente considerados como parte do suíno pela segmentação. Por fim, os FN são os pixels dos contornos do suíno e da área do suíno que não foram identificados pela segmentação, em contraste com a segmentação manual. Eles representam partes do suíno que o método de segmentação não conseguiu identificar corretamente.

2.2.3.3 Extração de características

A extração dos dados das amostras foi da região de interesse segmentada anteriormente e consistiram nos valores de temperatura superficial da pele dos animais. Para extrair os valores de temperatura das imagens térmicas foi desenvolvido uma rotina utilizando como dados de entrada, as imagens segmentadas, a faixa de variação de temperaturas expressas nas escalas da imagem e as informações dos pixels da paleta de cor arco-íris do software *FLIR Tools* empregada também no software *ThermaCam*.

A rotina cria uma grade de pontos sobre a imagem segmentada, com coordenadas sob distância entre pixels ajustável pelo usuário, sendo recomendável um mínimo de 30 pontos para representar a variabilidade da temperatura superficial do corpo do animal. O procedimento cria um vetor de temperaturas correspondentes à paleta de cores arco-íris. Nesse processo, a rotina percorre toda a imagem, analisam-se os pixels no formato RGB e emprega-se uma função de interpolação (Equação 4) para converter os valores de cor desses pixels em temperaturas, com base na paleta estabelecida.

$$f(x) = f(y_0) + \frac{f(y_1) - f(y_0)}{x_1 - x_0} \cdot (x - x_0) \quad (4)$$

em que, $f(x)$ é a temperatura interpolada, $f(y_1)$ e $f(y_0)$ são as temperaturas associadas a cores de dois pontos conhecidos na paleta, x_1 e x_0 são os índices desses pontos na paleta, representando as posições das cores mais próximas e a segunda mais próxima.

Para validar os dados de temperatura obtidos a partir das imagens infravermelhas por meio do algoritmo proposto foi utilizado como ferramenta de referência o software *ThermaCam Researcher* com uma licença de 30 dias, conforme usado na pesquisa de Wziątek-Kuczmik et al. (2022). Foram selecionadas 60 imagens para fins de testes e de cada uma, 30 pontos no corpo dos suínos, acompanhados de suas respectivas coordenadas relativas e valores de temperatura.

Em seguida, essas coordenadas relativas foram empregadas na ferramenta desenvolvida para extrair os valores de temperatura correspondentes. O desempenho da rotina foi avaliado por meio de métricas: Erro Médio Absoluto (MAE - Mean Absolute Error), Raiz Quadrada do Erro Médio (RMSE - Root Mean Squared Error) e o Coeficiente de determinação (R^2).

O MAE quantifica a média das diferenças absolutas entre os valores estimados pelo programa *ThermaCam* e o algoritmo proposto. A representação matemática está explícita na Equação 5.

$$MAE = \frac{1}{n} * \sum_{1-n}^n |\text{Temp. do } ThermaCam - \text{Temp. algoritmo proposto}| \quad (5)$$

A Raiz Quadrada do Erro Médio (RMSE - Root Mean Squared Error) calcula a raiz quadrada da média dos quadrados das diferenças entre os do programa *ThermaCam* e o algoritmo proposto (Equação 6).

$$RMSE = \sqrt{\frac{1}{n} * \sum_{1-n}^n (\text{Temp. do } ThermaCam - \text{Temp. algoritmo proposto})^2} \quad (6)$$

O Coeficiente de Determinação (R^2 - *Coefficient of Determination*) representa a proporção da variação nos valores obtidos pelo algoritmo proposto que pode ser explicada pela variação nos valores obtidos pelo programa *ThermaCam*. Ele fornece uma medida

da qualidade da predição, variando de 0 a 1. Um R^2 mais próximo de 1 indica uma predição mais precisa (Equação 7).

$$R^2 = 1 - \frac{\sum_{1-n}^n (\text{Temp. Software} - \text{Temp. estimada})^2}{\sum_{1-n}^n (\text{Temp. Software} - \text{Média da Temp. estimada})^2} \quad (7)$$

2.2.3.4 Reconhecimento e Interpretação - Classificador

Para a classificação dos animais em situações de conforto ou desconforto térmico, um método de *Machine Learning* foi usado o *Support Vector Machine* (SVM), ou Máquina de Vetor de Suporte. De acordo com Rodriguez et al. (2023) este método é usado para reconhecimento de padrões com objetivo de encontrar limites de decisão que separem classes de forma ótima, reduzindo erros de classificação. O SVM busca um hiperplano ou linha que separe os dados nas classes de conforto e desconforto, de forma que fique o mais distante possível de cada uma delas. Para Alfarzaei et al. (2023) esse modelo demonstra bom desempenho em conjuntos de dados de pequeno e de médio porte.

Foram utilizados como entrada os dados de temperatura superficial da pele extraídos de forma automática das imagens térmicas na etapa anterior. As imagens foram separadas por tratamento (ambiente climatizado e não climatizado). De cada imagem térmica foi extraído um total de 30 pontos totalizando 6780 e foi feito as médias. Cada imagem recebeu um rótulo com a identificação da situação em que os animais estavam inseridos, onde os animais em ambientes climatizados receberam o rótulo "conforto" (codificado como 0), enquanto aqueles nos ambientes não climatizados receberam o rótulo "desconforto" (codificado como 1), e esses rótulos foram registrados em uma planilha do Excel.

O treinamento foi realizado no *google colab*, iniciando com a importação das bibliotecas necessárias, como *pandas*, *scikit-learn* e *matplotlib*, importadas para manipulação de dados, treinamento do modelo e avaliação de desempenho.

Para preparar os dados de treinamento antes da modelagem foi realizada a normalização dos dados para que os valores ficassem dentro do intervalo 0 ou 1 e as variáveis de grandezas diferentes tivessem a mesma relevância para o algoritmo. A normalização foi realizada de acordo com a Equação 8, em que X_{max} e X_{min} são os maiores e menores valores da variável, respectivamente:

$$X \text{ norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (8)$$

Para encontrar a melhor combinação dos hiperparâmetros, implementou-se um algoritmo de busca aleatória, que seleciona valores de maneira randômica para os parâmetros do algoritmo SVM, como função do kernel, escala do kernel, e valor C, responsável por regular a penalidade máxima aplicada às observações que infringem a margem. Após a execução do algoritmo, os hiperparâmetros mais eficazes foram identificados e selecionados para prosseguir com o treinamento do modelo. Utilizando as funções de kernel de base radial (RBF), o treinamento foi conduzido com o modelo otimizado e as previsões foram realizadas no conjunto de teste.

A fim de obter uma avaliação mais robusta do desempenho do classificador, empregou-se uma validação cruzada de 5 vezes. O conjunto de dados foi particionado aleatoriamente em dois subconjuntos, sendo 70% (42 amostras) destinados ao treinamento e 30% (18 amostras) à predição. Este processo foi repetido em cinco iterações, cada uma selecionando aleatoriamente, dois terços diferentes dos dados para treinamento e o terço restante para predição, visando mitigar possíveis vieses na avaliação do modelo.

A avaliação do desempenho incluiu métricas como precisão (Equação 3) e acurácia (Equação 9).

$$\text{Acurácia} = \frac{PV+VN}{PV+VN+PF+VF} \quad (9)$$

Além disso, foi avaliado o índice AUC (Area Under the Curve) ou área sob a curva. Tal curva é a ROC (Característica de Operação do Receptor) e representa a taxa de verdadeiros positivos em relação à taxa de falsos positivos para diferentes valores de limiar de classificação. Quanto mais próxima a AUC estiver de 1, melhor é o desempenho do modelo em distinguir entre as classes. Se a AUC apresentar valor abaixo de 0,5, o modelo tem desempenho semelhante ao acaso.

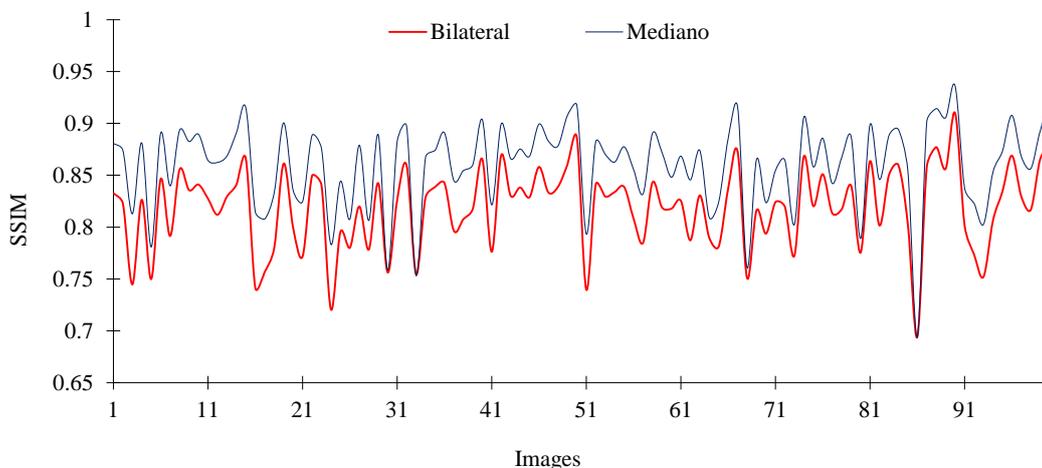
2.3 Resultados e Discussão

2.3.1 Pré-processamento

Os resultados do pré-processamento das imagens para a aplicação do método de Otsu estão representados na Figura 10. Nessa figura é possível observar o índice de

similaridade estrutural (SSIM) das imagens aprimoradas obtidas por meio da filtragem dos métodos bilateral e mediano, respectivamente.

Figura 10. Medida do Índice de Similaridade Estrutural.



Nota-se que o SSIM do filtro bilateral varia de 0,68 a 0,90, enquanto o filtro mediano varia de 0,69 a 0,93. O valor médio do SSIM para a filtragem bilateral e mediana apresenta valores semelhantes, com 0,82 e 0,86, reduzindo a melhoria na qualidade das imagens processadas. Entretanto, é importante ressaltar que as imagens aprimoradas pelo método mediano superam aquelas filtradas pelo método bilateral, uma vez que conseguem reduzir o ruído sem comprometer as informações das imagens, mostrando que o método mediano na supressão de ruídos foi mais eficaz. Essas observações estão alinhadas com os estudos de Draz et al. (2023) que destacam a eficácia do filtro mediano em situações de alto nível de ruído.

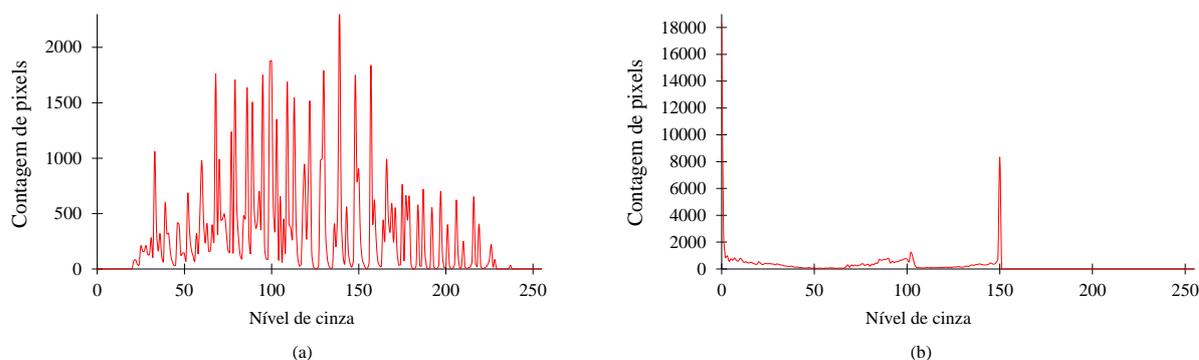
Os resultados obtidos estão próximos aos achados do estudo realizado por SINGH, et al. (2023), no qual eles aplicaram o filtro mediano em imagens de pulmões humanos e encontraram média para SSIM de 0,92. Nos resultados do estudo conduzido por Aghamaleki e Ghorbani (2023) foi constatado que os valores de SSIM com filtro mediano variam de 0,974 a 0,999. Isso evidencia que a aplicação dos filtros melhorou a qualidade da imagem após as técnicas de pré-processamento.

Bose et al. (2023) justificam o uso da aplicação das técnicas de pré-processamento como filtragem e segmentação, antes da extração de informações das imagens térmicas como sendo uma etapa necessária, com implicações para a qualidade e utilidade dos dados obtidos. Essas técnicas favorecem a eliminação de ruídos e o aprimoramento de características, contribuindo para diagnósticos precisos e confiáveis. A filtragem permite

que as imagens se tornem mais nítidas, o que contribui para facilitar a interpretação, enquanto a segmentação é importante para identificar e isolar regiões de interesse. A automação desses processos pode ser particularmente útil.

A Figura 11, exibe os histogramas da imagem original (a) e da imagem aprimorada (b), mostrando a distribuição da intensidade dos pixels (tons de cinza) em relação aos diferentes níveis de cinza na escala de 0 a 255.

Figura 11. Histograma da imagem original e da imagem aprimorada.



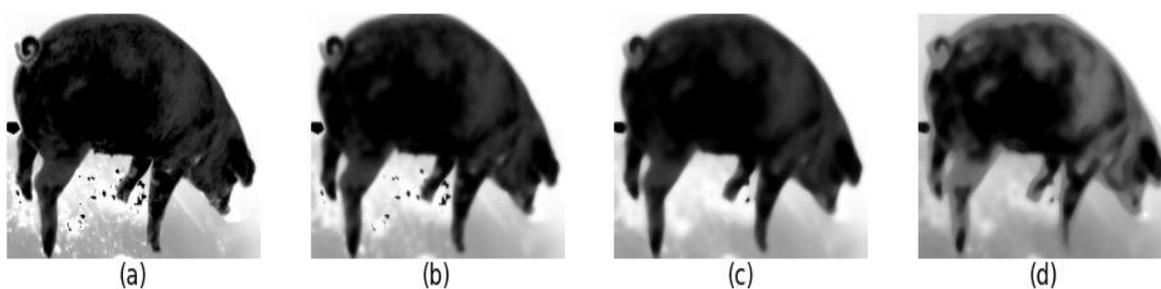
Na Figura 11, cada barra do histograma representa a quantidade de pixels que apresentam uma intensidade correspondente a uma faixa específica de tons de cinza na imagem. O pico no valor 2363 indica que há 2363 pixels na imagem com um nível de cinza de 133 (Figura 11a). No entanto, é possível observar que vários outros picos de pixels estão distribuídos por toda a imagem. Essa constatação está em concordância com os achados de Zhang et al. (2023), que também identificaram múltiplos picos no histograma da imagem. Esses picos podem ser atribuídos às discrepâncias na radiação térmica entre o fundo e a região de interesse na imagem, indicando uma concentração de valores em faixas específicas. Essa variação no histograma resalta a complexidade da distribuição de intensidade na imagem térmica, relacionada às características distintas de diferentes áreas da cena.

Na Figura 11b, a equalização do histograma contribuiu para distribuir as intensidades de forma mais uniforme, redistribuindo as intensidades dos pixels na imagem ao longo da faixa de intensidades disponíveis. Essa alteração foi observada nas áreas onde o contraste foi aprimorado e, as diferenças entre os níveis de cinza foram ampliadas. Contudo, mesmo com essas melhorias, ainda permanecem 18303 pixels com nível de cinza 0 e 2605 pixels com nível de cinza 1. Esses valores indicam áreas específicas na imagem que mantiveram uma intensidade mais baixa, possivelmente relacionada às características particulares da cena térmica. Vale destacar que, segundo

Zhu et al. (2023) a equalização do histograma pode transformar a distribuição de intensidades, ampliando a faixa dinâmica das diferenças de nível de cinza entre os pixels e melhorando o contraste geral da imagem térmica de polarização, embora alguns valores específicos ainda possam persistir.

A Figura 12 exibe os resultados das imagens na etapa de pré-processamento, em que foram aplicados os filtros bilateral e mediano nas imagens convertidas para o espaço HSV, seguidos pela equalização do histograma.

Figura 12. Remoção do canal H (a), filtro bilateral (b), filtro mediano (c) e equalização de histograma (d).



A imagem do animal antes da execução das etapas de pré-processamento pode se apresentar com ruídos, o que compromete sua qualidade para a segmentação. Além disso, em certas áreas, a distinção entre o corpo do animal e o fundo se torna imprecisa, tornando o processo de segmentação mais difícil. Na Figura 12a observa-se na escala de cinza que o canal H (Hue), no espaço de cores HSV, capturou a tonalidade e isolou as informações de cor da imagem, destacando o objeto de interesse.

A redução nos ruídos é notável na Figura 12b, graças à aplicação do filtro bilateral que suavizou a imagem. Este efeito é mais evidente na Figura 12c, em que o filtro mediano manteve a nitidez das bordas do objeto, enquanto suavizava os ruídos. Esses resultados foram corroborados pelo SSIM, em que as imagens tratadas com o filtro bilateral exibiram uma média de SSIM de 0.82, indicando qualidade inferior da imagem em comparação com o filtro mediano. Já, o filtro mediano demonstrou uma média de SSIM de 0,86, destacando um desempenho superior em preservar a estrutura e os detalhes da imagem.

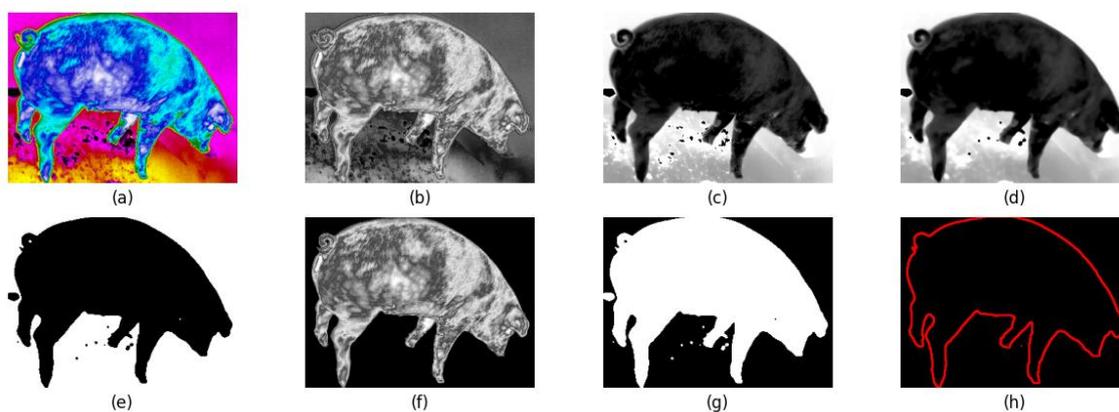
Na Figura 12d, o contraste foi aprimorado, realçando a diferença entre áreas claras e escuras da imagem. Essa etapa é fundamental para destacar os detalhes da imagem e facilitar a segmentação. No entanto, é importante notar que, mesmo com esses aprimoramentos, a presença residual de ruídos, sobretudo nas proximidades do corpo do

animal, pode afetar o processo de segmentação em algumas imagens. Esse comportamento é coerente com os resultados da pesquisa conduzida por Nazarudin et al. (2023) que aplicaram a equalização de histograma em imagens médicas, resultando em uma maior distinção entre as áreas claras e escuras das imagens. Dessa forma, optou-se pelo filtro mediano para suavizar e remover os ruídos das imagens.

2.3.1.2. Segmentação pelo método Otsu

Na Figura 13, observam-se os resultados das aplicações das técnicas de pré-processamento, na imagem original (Figura 13a) e nas imagens filtradas (Figuras 13b e 13c), bem como resultados da binarização de Otsu (Figura 13d), da binarização invertida (Figura 13e) e do contorno extraído (Figura 13f).

Figura 13. Imagem original (a), imagem original em tons de cinza (b), canal H (c), filtro mediano (d), binarização de Otsu (e), pixels isolados (f), imagem binarizada invertida (g) e contorno (h).

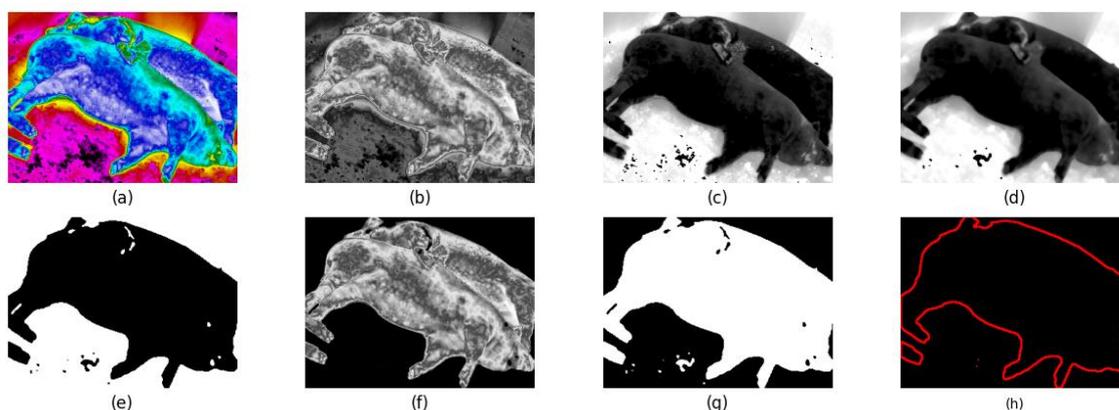


Na Figura 13b a imagem foi convertida para a tonalidade cinza, na 13c e d, a imagem foi melhorada, os ruídos foram removidos. O método de Otsu calculou automaticamente um limite de intensidade que separou o objeto do fundo, tornando a imagem binarizada, em que os pixels foram classificados em animal na cor preta (valor 0) e o fundo na cor branca (valor 255) (Figura 13e). Com isso, foi possível observar que somente os pixels associados aos objetos segmentados permaneceram visíveis na imagem, enquanto os pixels do fundo foram suprimidos, resultando em uma representação onde o fundo é representado como preto (valor 0) (Figura 13f). Na Figura 13g, após a aplicação da binarização de Otsu, foi aplicado a operação de inversão, em que os valores brancos se tornam pretos e os valores pretos se tornam brancos, para destacar

o objeto de interesse. A partir disso foi possível extrair o contorno da imagem segmentada (Figura 13h).

Dessa forma, foi possível visualizar que as regiões de interesse se destacam com nitidez em relação ao fundo, proporcionando uma representação clara e facilitando a análise e a identificação das áreas de interesse. No entanto, o algoritmo de segmentação proposto demonstra limitação quando os animais aparecem próximos na cena, ou quando apenas parte deles está visível, conforme ilustrado na Figura 14.

Figura 14. Imagem original (a), imagem original em tons de cinza (b), canal H (c), filtro mediano (d), binarização de Otsu (e), pixels isolados (f), imagem binarizada invertida (g) e contorno (h).



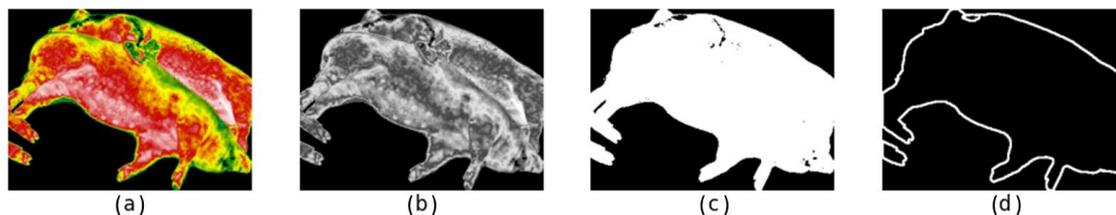
Nesses casos, a capacidade do algoritmo de diferenciar os objetos de interesse do fundo se destaca (Figura 14b-f), permitindo que ele reconheça e isole os animais, mesmo quando estão próximos ou parcialmente visíveis na imagem. Isso torna o método adequado para diversas situações e cenários em que a segmentação de objetos é necessária, independentemente da complexidade da cena. No entanto, o algoritmo não consegue distinguir o contorno individual dos animais quando eles compartilham a mesma área, ou estão deitados uns sobre outros (Figura 14g e 22h).

O algoritmo também tem limitações ao encontrar um limiar adequado para todas as imagens, devido à dessemelhança nas características das imagens. Algumas imagens têm bordas bem definidas, enquanto outras têm baixo ou alto contraste. No entanto, essa informação é condizente com a encontrada por Tamoor, Naseer e Khan, (2023) que observa a ausência de um método universal eficaz para todos os tipos de imagens.

2.3.1.3 Segmentação por cor

O sistema de segmentação automática com base no método de cor demonstrou um desempenho satisfatório na segmentação das imagens termográficas dos animais. A Figura 15 ilustra o resultado da segmentação.

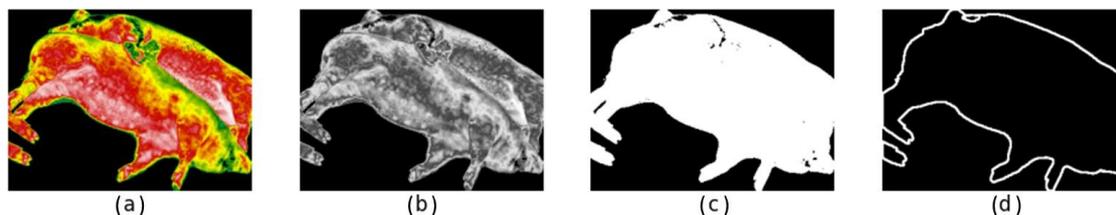
Figura 15. Cores segmentadas (a), pixels extraídos (b), máscara (c) e contorno (d).



Na Figura 15a o algoritmo de segmentação combinou várias faixas de cores com base nos intervalos predefinidos e destacou a região de interesse na imagem térmica. Na Figura 15b o algoritmo converteu a imagem segmentada para escala de cinza, binarizou a imagem (Figura 15c) e extraiu o contorno (Figura 15d).

Apesar de apresentar bons resultados nas segmentações, o algoritmo atuou de forma semelhante a segmentação de Otsu e não conseguiu individualizar os animais, conforme pode ser visto na Figura 16.

Figura 16. Imagem segmentada (a), imagem em cinza (b), máscara (c) e contorno (d).



Na Figura 16a o algoritmo de segmentação destacou as áreas de interesse contidas na imagem. Na Figura 16b o algoritmo converteu a imagem segmentada para tons de cinza. Na Figura 16c foi gerada uma máscara representando o objeto de interesse em branco (valor 255) e o restante do cenário em preto (valor 0) e na Figura 16d, o algoritmo não conseguiu determinar os contornos dos objetos segmentados, com base na aplicação do algoritmo *findContours* do *OpenCV* e extraiu um único contorno para os dois animais, o que representa uma limitação para o algoritmo proposto. Essas observações estão homologadas nos estudos de Carvalho e Coelho (2023) que destacam a eficácia da segmentação de imagens térmicas para a detecção de objetos de interesse.

2.3.1.4 Métricas de avaliação para as segmentações

O desempenho médio do Índice de Jaccard foi de 0,89. Esse achado está próximo aos valores encontrados no estudo de Dumitru et al. (2023) que encontraram índice de Jaccard variando de 0,70 a 0,90. Isso demonstra que essa segmentação é capaz de extrair a região de interesse e pode ser utilizada como sendo a de referência. De acordo com Queiroz et al. (2023) a segmentação de referência precisa representar a região de interesse na imagem sob análise, porém, alcançar uma segmentação perfeita, com um índice de Jaccard igual a 1, é uma meta que não ocorre na prática.

Esse resultado está em conformidade com as descobertas da pesquisa conduzida por Zhang et al. (2023), que também empregou a técnica de segmentação manual, sem atingir resultados de perfeição.

Os resultados das segmentações obtidas por meio do método de Otsu e da segmentação por cor são avaliados com base na média do coeficiente de Dice, no índice de Jaccard e na precisão entre as imagens segmentadas automaticamente e as segmentadas manualmente. Esse procedimento foi adotado com o propósito específico de identificar a combinação mais eficaz desses métodos, visando a otimização do processo de segmentação nesta fase da pesquisa. A Tabela 7 demonstra o desempenho médio das métricas de avaliação para os dois métodos de segmentação propostos.

Tabela 7. Métricas de avaliação para o desempenho das segmentações.

Métodos	Dice	Jaccard	Precisão
Otsu	0,89	0,81	0,87
Cor	0,90	0,83	0,88

A avaliação dos dados provenientes de todas as imagens revelou que o índice de Dice atingiu valores médios de 0,89 para Otsu e 0,90 para o método de segmentação por cor, respectivamente. Notou-se que o método de segmentação por cor, segmentou os animais mais precisamente, por apresentar o coeficiente de Dice maior. Um coeficiente de Dice maior indica melhor eficácia de segmentação (SRIVASTAVA et al., 2023). O coeficiente Dice de acordo com a pesquisa de Yan et al. (2023) serve como indicador da proporção da área que foi corretamente segmentada em comparação com a área total segmentada manualmente. Quanto mais próximo o coeficiente Dice estiver de 1, maior será a sobreposição e a concordância entre as áreas segmentadas automaticamente e manualmente. Esses resultados demonstram uma proximidade com os achados da pesquisa conduzida por Kumar et al. (2023), na qual o método de segmentação empregado alcançou o valor de Dice de 0,90.

O índice de Jaccard alcançou média de 0,81 para o método de segmentação de Otsu e 0,83 para a segmentação por cor. Dessa forma, o índice médio de Jaccard demonstra que as imagens segmentadas por cor foi o que apresentou resultados mais próximos da imagem segmentada de forma manual. Sharma et al. (2023) destacam que a eficácia de um método de segmentação analisado pode ser avaliada considerando o índice de Jaccard. Conforme suas conclusões, um índice de Jaccard mais próximo de 1 está associado a um desempenho superior, dessa forma, valores maiores indicam uma maior concordância entre os resultados obtidos e as referências estabelecidas. No estudo realizado por Kumar et al. (2023) foi identificado um índice de Jaccard de 0,82 em seu método de segmentação.

A média de precisão para o método de Otsu é de 87%, enquanto para a segmentação por Cor é de 88%. Esses resultados estão próximos aos obtidos no estudo de Gomathi, Muniraj e Periasamy (2023), onde a precisão média variou de 92 a 97%. Já Aleid et al. (2023) alcançaram uma precisão superior, com valor de 99,5% em seus resultados de segmentação.

Essas métricas, de acordo com Zhang et al. (2023), têm a capacidade de determinar se o método de segmentação avaliado é aplicável ou não. Dessa forma, para a extração de características, optou-se pelo método de segmentação por cor, por ter apresentado o melhor contorno de segmentação com base nas métricas de avaliação de desempenho.

De forma geral, os resultados obtidos nas medidas sobrepostas mostraram que houve 81% de intersecção entre as regiões segmentadas de forma automáticas e as regiões segmentadas manualmente. O algoritmo de segmentação conseguiu delimitar a região de interesse, mostrando que a segmentação automática avaliada pode ser implementada a análise de dados térmicos com baixa exigência computacional e destaca seu potencial para contribuir para o diagnóstico do estresse térmico em animais.

2.3.2 Extração de características

Os resultados das métricas de regressão, incluindo MAE, RMSE e R^2 , indicaram valores de 0,20 e 0,07 para o ambiente climatizado, e 0,25 e 0,09 para o ambiente não climatizado, respectivamente. O desempenho do algoritmo de extração de temperaturas em relação ao programa está apresentado na Tabela 8.

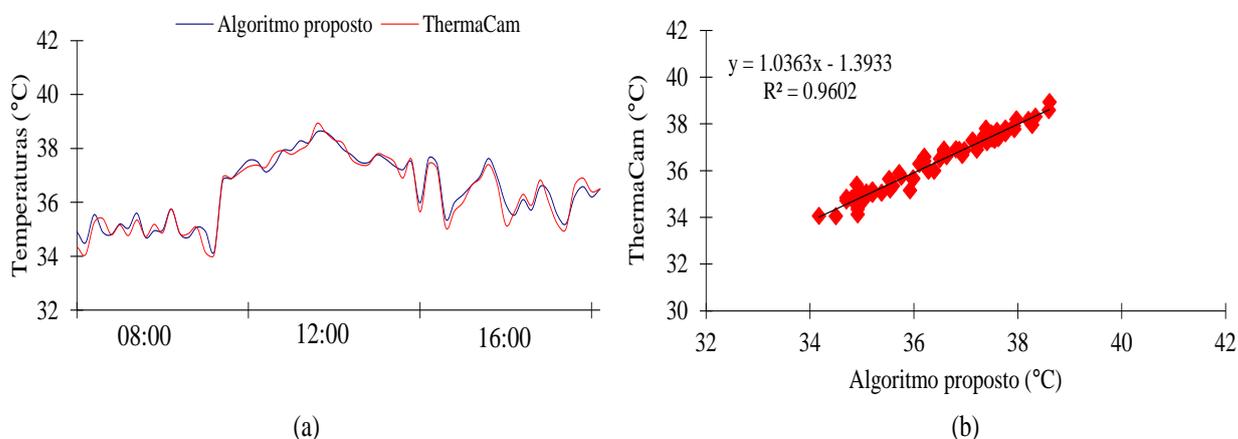
Tabela 8. Métricas de desempenho do algoritmo proposto para a extração de temperaturas das imagens térmicas.

Métricas	Ambiente climatizado	Ambiente não climatizado
MAE	0,20	0,25
RMSE	0,07	0,09
R ²	0,96	0,93

MAE - Mean Absolute Error; RMSE - Root Mean Squared Error; R² - Coeficiente de determinação

As médias de temperatura obtidas pelo algoritmo proposto e pelo programa *ThermaCam* no ambiente climatizado registradas às 08:00, 12:00 e 16:00 h, estão expressas na Figura 17.

Figura 17. Temperaturas superficiais médias para o ambiente climatizado obtidas via programa *ThermaCam* e algoritmo proposto (a). Regressão linear (b).

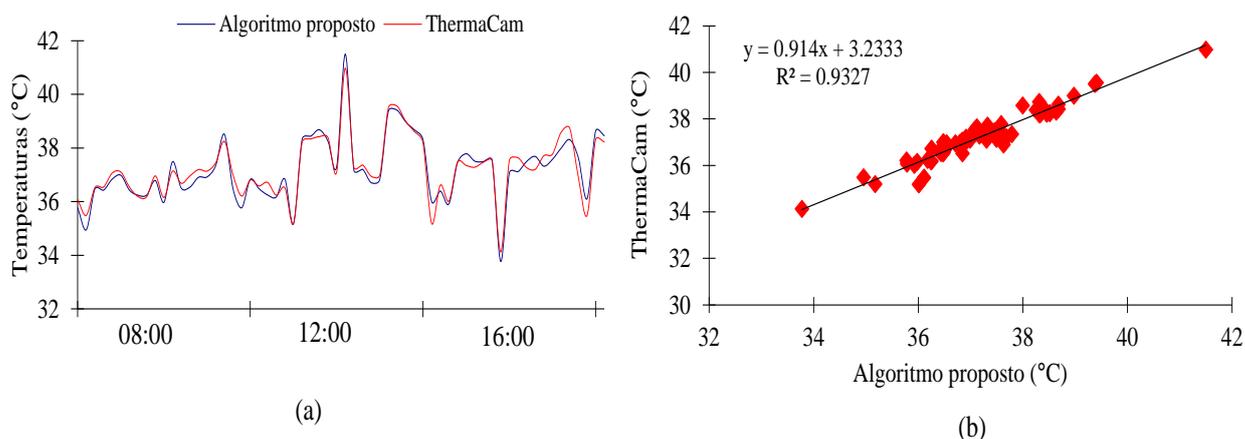


A Figura 17a demonstra que durante o período da manhã, as temperaturas da superfície dos suínos no ambiente climatizado variaram de 34,2 a 37,2°C. Às 12:00 h, a faixa de temperatura alcançou valores da ordem de 37,1 a 38,6°C, e por volta das 16:00 h, as temperaturas da pele dos animais diminuíram, oscilando entre 35,2 e 37,6°C. A diferença média entre os valores de temperatura obtida pelo algoritmo proposto e o programa *ThermaCam* foi de 0,20°C, a máxima foi de 0,80°C e a mínima foi de 0,00°C. Em alguns pontos, o algoritmo proposto fornece temperaturas ligeiramente mais baixas do que o *ThermaCam*, enquanto em outros casos, as temperaturas extraídas pelo algoritmo são ligeiramente mais altas. Na análise da Figura 17b, destaca-se que o coeficiente de determinação atingiu 0,96, indicando que aproximadamente 96% da variabilidade presente nos dados térmicos, conforme extraídos pelo algoritmo proposto,

pode ser explicada pelo algoritmo, demonstrando correspondência entre as temperaturas estimadas pelo algoritmo e aquelas provenientes do programa *ThermaCam*.

As médias de temperatura registradas as 08:00, 12:00 e 16:00 h obtidas pelo algoritmo proposto e pelo programa *ThermaCam* no ambiente sem climatizador, estão expressas na Figura 18.

Figura 18. Temperaturas superficiais médias para o ambiente sem climatizador (a).
Regressão linear (b).



Observa-se na Figura 18a que a variação da temperatura às 08:00 h foi de 34,95 a 37,49°C, às 12:00 h a variação foi de 35,18 a 41,50°C e às 16:00 h a variação foi de 33,77 a 38,31°C. A diferença média entre os valores de temperatura estimados pelo algoritmo proposto e o programa *ThermaCam* foi de 0,25°C, a máxima foi de 0,82°C e a mínima foi de 0,01°C. Na Figura 18b, observa-se que o coeficiente de determinação alcançou 0,93, indicando que aproximadamente 93% da variação nos dados térmicos, conforme extraídos pelo algoritmo, pode ser explicada pelo próprio algoritmo. Isso indica uma relação significativa entre as temperaturas estimadas e aquelas provenientes do programa *ThermaCam*, o que mostra a capacidade da técnica de extração de temperaturas.

Em relação as diferenças encontradas entre as temperaturas extraídas das imagens térmicas pela ferramenta desse estudo e o programa de referência utilizado, nota-se a necessidade de ajustes no algoritmo para aprimorar sua precisão em comparação a um software já estabelecido. As diferenças médias encontradas entre o algoritmo proposto e o *ThermaCam* pode estar relacionado ao uso do modelo matemático de natureza linear utilizado uma vez que a associação de pixels com as temperaturas das imagens térmicas, pode não ser adequadamente representada por uma função linear. Isso se deve ao padrão

das respostas térmicas dos animais, que variam em diferentes condições ambientais, conforme a pesquisa conduzida por Tito et al., (2023) onde argumentam que a precisão das imagens térmicas é influenciada pelo ambiente. Wang et al., (2023) citaram que a precipitação, o vento, a umidade, o vento e a temperatura do ar afetam os resultados das imagens térmicas.

No ambiente sem climatizador, à ausência de neblina sob a pele dos animais, impacta os padrões térmicos e a relação entre os valores dos pixels e as temperaturas reais. Além disso, o comportamento dos animais, como se deitar sobre fezes e urina para dissipar calor, contribui para essa não linearidade. Fatores ambientais também, como temperatura e umidade, cria um ambiente mais complexo, que também influenciam as respostas térmicas não lineares. O uso de uma função linear para associar pixels às temperaturas não leva em conta a dinâmica térmica complexa e não linear que ocorre em ambientes não controlados.

Apesar de existir diferenças entre as temperaturas estimadas e as de referência, o algoritmo proposto oferece vantagens significativas para a extração de temperaturas a partir de imagens térmicas. Conforme apontado por Irujo (2022), os programas integrados em câmeras infravermelhas frequentemente apresentam funcionalidades limitadas devido à sua natureza de código fechado, sendo projetados principalmente para usuários não científicos, devido custos financeiros. Ao contrário, a ferramenta desenvolvida neste estudo destaca-se por seu potencial no meio científico, uma vez que foi desenvolvida em código aberto e apresenta flexibilidade para adaptações.

Além disso, nos softwares associados as imagens térmicas, conforme indicado por Nosrati et al. (2020) é necessário a escolha manual de pontos de temperatura ou áreas, o que se torna impraticável quando há a necessidade de lidar com um grande volume de imagens. O método proposto no estudo emprega um espaçamento entre pixels definido pelo usuário (sendo recomendado um mínimo de 30 pontos), com a extração realizada de maneira totalmente automatizada. Essa forma de obter as temperaturas em um espaçamento fixo entre pixels, também foi adotada no trabalho de Borges et al. (2022), onde os autores fizeram uso de análise de temperatura de imagens térmicas de casco de bezerros definindo uma distância fixa entre pixels.

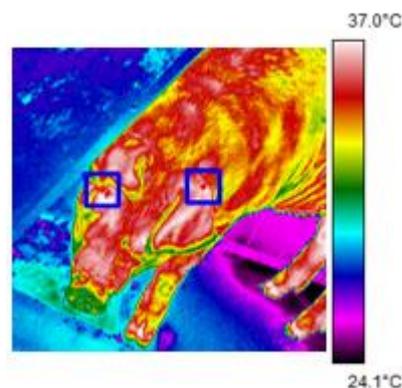
Outro ponto destacado na investigação de Cramer et al. (2020) é a escolha de diferentes paletas de cores em softwares empregados para imagens térmicas, podendo comprometer a representação precisa dos dados. O método adotado neste estudo emprega a paleta de cores recomendada para tecidos biológicos, a arco-íris com valores mais frios

em preto e valores mais quentes em branco. Para imagens térmicas esta paleta é a mais adequada, conforme indicado por Shaikh; Akhter e Manza (2019) por indicar a menor variação de temperatura.

Outros algoritmos de código aberto foram criados para obter dados brutos de imagens térmicas; contudo, eles dependem de um segundo software adicional para realizar a extração dos dados das imagens, a exemplo do software IRimage de código aberto desenvolvido na pesquisa de Irujo (2022) que utiliza o software *exitool* como complemento. O método sugerido neste estudo utiliza as informações da paleta de cores e interpolação matemática, para adquirir os valores brutos de temperatura das imagens.

O algoritmo proposto também pode receber um arquivo contendo as coordenadas relativas e extrair os valores de temperatura dessas coordenadas. Além disso, ele também determina automaticamente as regiões mais quente do corpo do animal, o que pode ser útil na identificação de doenças localizadas, ou na identificação das regiões que possuem maior correlação com a temperatura retal, como orelhas e região ocular, conforme visualizado na Figura 19.

Figura 19. Região de maior temperatura superficial detectada pelo algoritmo proposto.



Conforme ilustrado na Figura 19, o algoritmo proposto destacou a região ocular e da orelha como as áreas de maior temperatura do animal. As áreas identificadas pelo algoritmo coincidem com aquelas investigadas por Gorczyca et al. (2018), que buscavam prever a temperatura retal em suínos por meio de redes neurais. As temperaturas superficiais dos animais mostraram correlação com as temperaturas do núcleo, e os pesquisadores observaram que as regiões da orelha e do olho exibiram as temperaturas mais elevadas.

Além disso, a relação entre as áreas identificadas pelo algoritmo e as regiões investigadas por Gorczyca et al. (2018) fortalece a confiabilidade dos resultados obtidos.

A identificação da região ocular e orelha como as mais quentes pode ter implicações significativas, sugerindo a viabilidade dessas áreas como indicadores confiáveis das temperaturas internas do suíno. Essa correspondência entre os resultados do algoritmo e a pesquisa anterior valida a eficácia da abordagem proposta. A precisão na identificação dessas regiões quentes reforça a utilidade do algoritmo não apenas na detecção térmica, mas também no potencial da predição de parâmetros fisiológicos essenciais para o monitoramento da saúde dos animais.

2.3.3 Avaliação do conforto térmico

As variáveis ambientais registradas nas baias com climatização indicaram uma variação na temperatura do ar de 23,08 a 22,87°C e na umidade relativa de 70,30 a 84,79%. Esses valores de temperatura situam as instalações dentro das faixas adequadas de temperatura do ar para animais nas fases de crescimento (22-26°C), conforme definido por Perdomo et al. (1985). Os resultados obtidos nesse ambiente apresentaram valores de temperaturas próximos aos de Kiefer et al. (2009) que encontraram valores de temperatura entre 18 e 26°C e UR de 75% para suínos em crescimento em ambientes climatizados.

A temperatura e a umidade relativa do ar nas baias sem climatização apresentaram variação de 24,55 a 34,94°C e de 74,72 a 50,64%, respectivamente, valores que excedem o limiar indicativo de conforto térmico conforme definido por Perdomo et al. (1985).

Os resultados da análise estatística demonstraram o perfil térmico dos animais submetidos aos diferentes sistemas de climatização (Tabela 9).

Tabela 9. Estatística descritiva da temperatura superficial dos suínos.

<u>Estatísticas</u>	<u>Ambiente climatizado</u>	<u>Ambiente natural</u>
Média	30,40 a 35,70°C	33,02 a 38,38°C
Mínimo	22,80°C	34,10°C
Máximo	38,40°C	42,80°C

A temperatura média da superfície da pele dos animais submetidos ao ambiente climatizado variou de 30,40 a 35,70°C. O valor médio mínimo e máximo de temperatura na pele dos animais foi de 22,80 e de 38,40°C. O valor médio identificado nesta pesquisa se apresenta próximos com os dados obtidos em estudos correlatos que estudaram à análise da temperatura cutânea de suínos em ambientes climatizados. Conforme evidenciado por Crone et al. (2023), a temperatura média registrada durante o transporte desses animais em condições climatizadas foi de 34°C. De maneira análoga, Santos et al.

(2018) observaram, em seu estudo, que a temperatura média dos suínos em ambiente provido de lâmina de água situou-se em 34,50°C. Na pesquisa de Vásquez et al. (2022) em suínos dentro de ambientes de criação dentro da zona termoneutra para animais em crescimento (em torno de 23°C) apresentou valores da pele de 39,1°C.

A temperatura média dos animais submetidos ao ambiente natural (sem climatizador) foi de 33,02 e 38,38°C. Os valores mínimo e máximo encontrados na superfície dos animais do ambiente natural foi de 34,10 e 42,80°C. A temperatura máxima de 42,80°C registrada na pele dos animais, demonstra que os animais apresentaram estresse térmico elevado, uma vez que a literatura apresenta uma temperatura máxima de 36°C para animais em um ambiente de temperatura confortável (CRONE et al., 2023). Isso mostra que os animais submetidos ao ambiente sem climatizador excedem a temperatura corporal normal. Cabe destacar que esse cenário ilustra um padrão esperado mostrando que quando os animais estão com temperaturas fora da zona termoneutra, os efeitos do microclima são observados na superfície dos animais.

Resultados semelhantes foram identificados no estudo de Brown-Brandl et al. (2023b), que revelou temperaturas máximas na pele de suínos variando de 40°C para animais da raça Duroc a 41,9°C para suínos de outras raças, em diferentes temperaturas do ar. Na pesquisa desenvolvida por Vásquez et al. (2022) a temperatura cutânea de suínos em fase de crescimento, em ambientes naturais, variou entre 41,0 e 41,5 °C.

Na pesquisa conduzida por Jia et al. (2020), identificaram-se valores máximos de temperatura na pele de suínos, atingindo 39,12°C em um ambiente com temperatura do ar de 33,10°C e umidade relativa do ar de 91,80%. Os autores destacam que a temperatura do ar e a umidade relativa exercem influência nas temperaturas cutâneas dos animais por meio de processos como convecção, condução e outros mecanismos de transferência de calor. Esses achados evidenciam que a temperatura cutânea resulta de uma interação complexa entre fatores ambientais e a temperatura interna do corpo.

O estudo identificou padrões térmicos nos animais sob os diferentes ambientes de produção. O perfil térmico dos animais submetidos ao estresse térmico demonstrou um padrão perceptível diferente dos animais sob a climatização. Com base na pesquisa de Alves et al. (2023) compreender como os suínos respondem às diversas condições ambientais é essencial para garantir o seu bem-estar e otimizar a eficiência da produção.

Ao analisar o perfil térmico dos suínos, os pesquisadores e produtores podem desenvolver estratégias eficazes de controle térmico do ambiente de criação para mitigar

os potenciais efeitos adversos dos extremos de temperatura no comportamento e na produtividade dos suínos.

2.3.4 Classificador

No cenário de classificação, o SVM demonstrou ser capaz de classificar os animais em situação de conforto e desconforto térmico utilizando as informações da temperatura da superfície da pele, conforme exposto na Tabela 10.

Tabela 10. Desempenho do classificador SVM.

Métricas de desempenho		
Precisão	Acurácia	*AUC
0,80	0,91	1,00

*AUC: Area Under the Curve ou área sob a curva

O modelo classificou corretamente 91% das instâncias e forneceu precisão de classe de 80%. No trabalho de Wang et al. (2023), o SVM foi empregado para estabelecer o estro em vacas, utilizando a variação da temperatura infravermelha térmica e alcançou precisão de 81,42%.

No trabalho apresentado por Jaddoa; Gonzalez e Cuthbertson (2021) foi proposto um método automático de segmentação ocular fundamentado em imagens térmicas. O emprego do SVM como classificador foi adotado para segmentar a região da face da vaca. Posteriormente, técnicas automáticas de processamento de limites, detecção de pontos quentes e refinamento foram aplicadas para segmentar os olhos do animal. Os resultados revelaram que a precisão deste método atingiu 72,12%.

Zhang; Kang e Ma (2019) para realizar o posicionamento automático dos olhos e úberes das vacas, analisaram o histograma da imagem infravermelha térmica, seguido pela detecção automatizada da posição dos olhos com base nos componentes Matiz, Saturação e Valor (HSV) na imagem. Posteriormente, utilizaram a tecnologia de classificação SVM para identificar automaticamente a posição do úbere da vaca. Os resultados indicaram uma precisão de 68,67% no reconhecimento de quadros de vídeo, com erro de posicionamento inferior a 20 pixels. Além disso, a precisão de detecção desse método para mastite clínica atingiu 87,5%

Na pesquisa conduzida por Saeedi et al. (2023) a precisão do SVM foi de 80% para classificar tumores cerebrais em imagens médicas. Já na pesquisa de McIntyre e Tuba (2023) os autores usaram o SVM para classificar tumores cerebrais em imagens médicas e obtiveram precisão superior de 91,21%.

Dessa forma, o modelo SVM reconheceu padrões nas distribuições de temperatura que caracteriza animais sob conforto e desconforto térmico. Os suínos são sensíveis ao calor e tendem a oferecer respostas do ambiente onde estão submetidos. Temperaturas superficiais e comportamentos específicos, como deitado, estão significativamente correlacionadas com o conforto térmico, conforme Andersen et al. (2008), que citam que a temperatura da pele, bem como o comportamento deitado são utilizados como um índice do estado térmico dos suínos, o que é significativo e foi observado nesta pesquisa. Deitar-se na posição totalmente reclinada aumenta a perda de calor com o piso.

Esses dados podem ser considerados indicadores para estimar o conforto térmico de suínos em diferentes ambientes térmicos. As imagens térmicas possuem capacidade de fornecer informações precisas sobre a condição dos animais, especialmente em relação ao estresse por calor, imagens com temperaturas mais elevadas podem indicar que os animais estão sob estresse térmico.

Ao analisar tanto as temperaturas superficiais dos suínos, o modelo SVM classificou as imagens, contribuindo para a identificação precoce de situações de estresse por calor nos animais e facilitando a implementação de medidas corretivas. A ferramenta resultante deste estudo pode ser empregada como um apoio ao diagnóstico, auxiliando médicos veterinários na adoção de medidas preventivas, pois os efeitos prejudiciais do estresse térmico nos suínos variam desde a redução do desempenho até problemas de saúde.

O algoritmo proposto pode ser empregado para analisar imagens térmicas originais adquiridas por meio de uma câmera térmica conectada a um computador e armazenamento em nuvem. Para Hoffer et al. (2023) essas câmeras térmicas apresentam um custo relativamente baixo, o que pode ser uma vantagem para a implementação do algoritmo proposto. O algoritmo proposto carrega a imagem, realiza análise, segmentação e detecção das temperaturas da superfície corporal de suínos com base nas imagens capturadas, dispensando a necessidade de contato direto. Essa técnica simplifica o monitoramento dos animais, permitindo a identificação de temperaturas corporais mais elevadas e pode auxiliar no diagnóstico médico veterinário.

De acordo com Conceição et al. (2023) a temperatura corporal é um importante indicador de saúde animal, uma vez que por meio dela podem ser detectados estresses, inflamações locais e patologias no geral. Dessa forma, essa ferramenta pode contribuir significativamente para a produção suína, uma vez que tem o potencial de identificar precocemente a presença de doenças e prevenir a propagação, auxiliando no controle e

otimizando a alocação de recursos na produção animal, por meio de um monitoramento mais eficiente dos suínos.

Além disso, a proposta pode ser adaptada para a contabilização da frequência respiratória, conforme demonstrado por Stewart et al. (2017), que utilizaram imagens térmicas das narinas de gado para medir a diferença de temperatura durante a inspiração e expiração, validando a utilização da termografia como uma técnica não invasiva e remota para a medição da frequência respiratória. Essas aplicações resultarão em benefícios tanto para a saúde dos animais quanto para a eficiência da produção suína como um todo.

A utilização desse procedimento, ocorre sem contato direto com o animal, o que contribui para a precisão da coleta de dados e promove o bem-estar dos suínos, garantindo um ambiente mais tranquilo e livre de interferências humanas indesejadas Coşkun et al. (2023). Dessa forma, a proposta pode representar um avanço significativo na forma de monitorar animais na produção suína.

2.4 Conclusões

Este estudo apresentou uma metodologia sequencial para a extração automatizada de características em imagens térmicas, seguida pela classificação do estresse térmico em suínos por meio de técnicas de aprendizado de máquina. O método de segmentação mais eficiente demonstrou ser baseado na cor, com um coeficiente de similaridade de 0,90, e os resultados da extração de características, estimados pelo algoritmo proposto, divergiram em 0,80°C em relação ao programa de referência. O modelo de aprendizado de máquina exibiu uma precisão de 80% e uma acurácia de 91%, permitindo a detecção e classificação automáticas de suínos em estados de conforto e desconforto térmico. Para futuras melhorias é sugerido explorar a aplicação de modelos matemáticos mais complexos no algoritmo de extração de características e realizar testes com diferentes modelos de aprendizado de máquina.

Referências

AGHAMALEKI, J. A.; GHORBANI, A. Image fusion using dual tree discrete wavelet transform and weights optimization. **Visual Computer**, v. 39, n. 3, p. 1181–1191, 2023. Springer Berlin Heidelberg. Disponível em: <<https://doi.org/10.1007/s00371-021-02396-9>>.

ALEID, A.; ALHUSSAINI, K.; ALANAZI, R.; et al. Artificial Intelligence Approach for Early Detection of Brain Tumors Using MRI Images. **Applied Sciences** 2023, Vol. 13,

Page 3808, v. 13, n. 6, p. 3808, 2023. Multidisciplinary Digital Publishing Institute. Disponível em: <<https://www.mdpi.com/2076-3417/13/6/3808/htm>>. Acesso em: 8/12/2023.

ALFARZAEAI, M. S.; HU, E.; PENG, W.; QIANG, N.; ALKAINAEAI, M. M. A. Coal Gangue Classification Based on the Feature Extraction of the Volume Visual Perception ExM-SVM. **Energies**, v. 16, n. 4, p. 1–18, 2023.

ALVES, M. de F. A.; PANDORFI, H.; MONTENEGRO, A. A. DE A.; et al. Evaluation of Body Surface Temperature in Pigs Using Geostatistics. **AgriEngineering**, v. 5, n. 2, p. 1090–1103, 2023.

ALVES, F.; GOMES, R. D. C.; KARVATTE JUNIOR, N.; de OLIVEIRA, C. C. **Bem-estar animal**: desafios, oportunidades e perspectivas globais. 2020.

ANDERSEN, H. M. L.; JØRGENSEN, E.; DYBKJÆR, L.; JØRGENSEN, B. The ear skin temperature as an indicator of the thermal comfort of pigs. **Applied Animal Behaviour Science**, v. 113, n. 1–3, p. 43–56, 2008. Acesso em: 8/12/2023.

BARBOSA FILHO, J. A. D., SILVA, I. J. O.; SILVA, M. A. N.; SILVA, C. J. M. Avaliação dos comportamentos de aves poedeiras utilizando sequência de imagens. **Engenharia Agrícola**, v. 27, n. 1, p. 93–99, 2007.

BARELI FELIPE. **Introdução à Visão Computacional: Uma abordagem prática com python e OpenCV**. 2019.

BORGES, P. A. C.; SILVA, D. C.; DA SILVA, N. A. A.; et al. Different methods of processing thermographic images to evaluate the carpal temperature of healthy calves. **Ciencia Animal Brasileira**, v. 23, 2022. Universidade Federal de Goiás. Acesso em: 8/12/2023.

BOSE, ANANYA; MAULIK, UJJWAL; SARKAR, A. An entropy-based membership approach on type-II fuzzy set (EMT2FCM) for biomedical image segmentation. **Engineering Applications of Artificial Intelligence**, v. 127, p. 107267, 2023.

BROWN-BRANDL, T. M.; HAYES, M. D.; ROHRER, G. A.; EIGENBERG, R. A. Thermal comfort evaluation of three genetic lines of nursery pigs using thermal images. **Biosystems Engineering**, v. 225, p. 1–12, 2023a. Academic Press.

BROWN-BRANDL, T. M.; HAYES, M. D.; ROHRER, G. A.; EIGENBERG, R. A. Thermal comfort evaluation of three genetic lines of nursery pigs using thermal images. **Biosystems Engineering**, v. 225, p. 1–12, 2023b. Academic Press..

CAI, Z.; CUI, J.; YUAN, H.; CHENG, M. Application and research progress of infrared thermography in temperature measurement of livestock and poultry animals: A review. **Computers and Electronics in Agriculture**, v. 205, 2023. Elsevier B.V. Acesso em: 8/12/2023.

CEZÁRIO, G.; MAGRINELLI, G.; SANTOS, J.; CAVALIERI, F.; ANDREAZZI, M. Uso racional de antibióticos na criação de suínos. **Enciclopédia Biosfera**, v. 17, n. 34, 2020.

CONCEIÇÃO, A. R.; COELI, A. C.; BRAGA, P. H. S.; OLIVEIRA, P. DA C. S.; SCHULTZ, E. B. Tecnologias aplicadas ao monitoramento de parâmetros fisiológicos na produção de ruminantes. **Revista Agraria Academica**, v. 6, n. 2, p. 27–37, 2023. *Revista Agraria Academica*. Acesso em: 8/12/2023.

COŞKUN, G.; ŞAHIN, Ö.; DELIALIOĞLU, R. A.; ALTAY, Y.; AYTEKIN, İ. Diagnosis of lameness via data mining algorithm by using thermal camera and image processing method in Brown Swiss cows. **Tropical Animal Health and Production**, v. 55, n. 1, 2023.

CRAMERI, FABIO; SHEPHARD, GRACE E.; HERON, P. J. The misuse of colour in science communication. **Nature communications**, v. 11, n. 1, p. 5444, 2020.

CRONE, C.; CALDARA, F. R.; MARTINS, R.; et al. Environmental Enrichment for Pig welfare during Transport. **Journal of Applied Animal Welfare Science**, v. 26, n. 3, p. 393–403, 2023. Taylor and Francis Ltd. Disponível em: <https://www.researchgate.net/publication/355009910_Environmental_Enrichment_for_Pig_welfare_during_Transport>. Acesso em: 8/12/2023.

DINIZ, C. D. DA S. C.; ATAÍDE, E. M. Different substrates in the germination of pomegranate seeds. **Brazilian Journal of Animal and Environmental Research**, v. 6, n. 2, p. 1876–1882, 2023.

DRAZ, H. H.; ELASHKER, N. E.; MAHMOUD, M. M. A. Optimized Algorithms and Hardware Implementation of Median Filter for Image Processing. **Circuits, Systems, and Signal Processing**, v. 42, n. 9, p. 5545–5558, 2023. Birkhauser. Disponível em: <<https://link.springer.com/article/10.1007/s00034-023-02370-x>>. Acesso em: 8/12/2023.

DUMITRU, R. G.; PETELEAZA, D.; CRACIUN, C. Using DUCK-Net for polyp image segmentation. **Scientific Reports**, v. 13, n. 1, 2023. Nature Research. Disponível em: <https://www.researchgate.net/publication/371638717_Using_DUCK-Net_for_polyp_image_segmentation>. Acesso em: 8/12/2023.

ELISSON CARLOS DE CARVALHO, ALESSANDRA MARTINS COELHO, A. C. & M. DE F. O. B. U-Net Convolutional Neural Networks for breast IR imaging segmentation on frontal and lateral view. **Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization**, v. 11, n. 3, p. 311–316, 2023.

GODYŃ, D.; HERBUT, P. Applications of continuous body temperature measurements in pigs – a review. **Annals of Warsaw University of Life Sciences - SGGW - Animal Science**, v. 56, n. 2, p. 209–220, 2018. Warsaw University of Life Sciences – SGGW Press. Disponível em: <https://www.researchgate.net/publication/323271275_Applications_of_continuous_body_temperature_measurements_in_pigs_-_a_review>. Acesso em: 8/12/2023.

GOMATHI, P.; MUNIRAJ, C.; PERIASAMY, P. S. Digital infrared thermal imaging system based breast cancer diagnosis using 4D U-Net segmentation. **Biomedical Signal Processing and Control**, v. 85, n. 5, p. 104792, 2023.

GONZALEZ, R. WOODS, P. **Digital image processing**. 2007.

GORCZYCA, M. T.; MILAN, H. F. M.; MAIA, A. S. C.; GEBREMEDHIN, K. G. Machine learning algorithms to predict core, skin, and hair-coat temperatures of piglets. **Computers and Electronics in Agriculture**, v. 151, p. 286–294, 2018. Elsevier B.V. Acesso em: 8/12/2023.

HE, J., ZHANG, X., LI, S., & GAN, Q. Effects of ambient temperature and relative humidity and measurement site on the cow's body temperature measured by infrared thermography. **Journal of Zhejiang University (Agriculture and Life Sciences)**, v. 46, n. 4, p. 500–508, 2020.

HOFFER, O.; RABIN, T.; NIR, R. R.; et al. Automated thermal imaging monitors the local response to cervical cancer brachytherapy. **Journal of Biophotonics**, v. 16, n. 1, p. e202200214, 2023. John Wiley & Sons, Ltd. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1002/jbio.202200214>>. Acesso em: 8/12/2023.

IRUJO, G. P. IRimage: Open source software for processing images from infrared thermal cameras. **PeerJ Computer Science**, v. 8, p. e977, 2022. PeerJ Inc. Disponível em: <<https://peerj.com/articles/cs-977>>. Acesso em: 8/12/2023.

JIA, G.; LI, W.; MENG, J.; TAN, H.; FENG, Y. Non-Contact Evaluation of Pigs' Body Temperature Incorporating Environmental Factors. **Sensors 2020, Vol. 20, Page 4282**, v. 20, n. 15, p. 4282, 2020. Multidisciplinary Digital Publishing Institute. Disponível em: <<https://www.mdpi.com/1424-8220/20/15/4282/htm>>. Acesso em: 8/12/2023.

KIEFER, C., MEIGNEN, B. C. G., SANCHES, J. F., & CARRIJO, A. S. Resposta de suínos em crescimento mantidos em diferentes temperaturas. **Archivos de zootecnia**, v. 58, n. 221, p. 55–64, 2009.

LIU, Y.; WANG, F.; LIU, K.; et al. Deep convolutional autoencoder thermography for artwork defect detection. **Quantitative InfraRed Thermography Journal**, 2023. Taylor & Francis. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/17686733.2023.2225246>>. Acesso em: 8/12/2023.

MACHADO, N.; BARBOSA-FILHO, J. A. D.; MARQUES, J. I.; et al. Infrared Thermography as a Non-Invasive Method to Quantify the Heat Stress Response in Weaned Pigs after Road Transport in a Semi-Arid Region. **Available at SSRN**, p. 4394502, 2023. Disponível em: <<https://papers.ssrn.com/abstract=4394502>>. Acesso em: 8/12/2023.

M.A. JADDOA, L. GONZALEZ, H. CUTHBERTSON, A. A.-J. Multiview eye localisation to measure cattle body temperature based on automated thermal image processing and computer vision. **Infrared Physics & Technology**, v. 119, 2021.

MCINTYRE, L., & TUBA, E. Brain Tumor Segmentation and Classification using Texture Features and Support Vector Machine. **11th International Symposium on Digital Forensics and Security (ISDFS)**, p. 1–5, 2023.

MCMANUS, R.; BODEN, L. A.; WEIR, W.; et al. Thermography for disease detection in livestock: A scoping review. **Frontiers in Veterinary Science**, v. 9, 2022.

M. KALAIYARASI, R. JANAKI, A. SAMPATH, DHARMENDRA GANAGE, Y. D. C. & S. B. Non-additive noise reduction in medical images using bilateral filtering and modular neural networks. **Soft Comput**, p. 1–10, 2023.

NAZARUDIN, A. A.; ZULKARNAIN, N.; MOKRI, S. S.; et al. Performance Analysis of a Novel Hybrid Segmentation Method for Polycystic Ovarian Syndrome Monitoring. **Diagnostics**, v. 13, n. 4, 2023.

NOSRATI, Z.; BERGAMO, M.; RODRÍGUEZ-RODRÍGUEZ, C.; SAATCHI, K.; HÄFELI, U. O. Refinement and validation of infrared thermal imaging (IRT): a non-invasive technique to measure disease activity in a mouse model of rheumatoid arthritis. **Arthritis Research and Therapy**, v. 22, n. 1, p. 1–16, 2020. BioMed Central Ltd. Disponível em: <<https://arthritis-research.biomedcentral.com/articles/10.1186/s13075-020-02367-w>>. Acesso em: 8/12/2023.

OTSU, N. A. Threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, v. 9, n. 1, p. 62–66, 1979.

PERDOMO CC, KOZEN EA, SOBESTIANSKY J, SILVA AP, C. NI. Considerações sobre edificações para suínos. In: C. EMBRAPA; S. e Aves (Orgs.); Curso de Atualização sobre a Produção de Suínos. **Anais...**, 1985. Concórdia, SC.

DA QUEIROZ, K. F. F. C.; DE QUEIROZ JÚNIOR, J. R. A.; DOURADO, H.; DE LIMA, R. DE C. F. Automatic segmentation of region of interest for breast thermographic image classification. **Research on Biomedical Engineering**, v. 39, n. 1, p. 199–208, 2023. Springer International Publishing. Disponível em: <<https://doi.org/10.1007/s42600-023-00265-z>>.

DOS REIS, H. S., DA PAZ, C. D., COCOZZA, F. D. M., DE OLIVEIRA, J. G. A., & SILVA, M. A. V. PLANTAS MEDICINAIS DA CAATINGA: UMA REVISÃO INTEGRATIVA DOS SABERES ETNOBOTÂNICOS NO SEMIÁRIDO NORDESTINO. **Arquivos De Ciências Da Saúde Da UNIPAR**, v. 27, n. 2, p. 874–900, 2023.

RODRIGUEZ, P. C. L.; FRANCA, A. S.; PEREIRA, F. G.; et al. Máquina De Vetores De Suporte Para Classificação De Anomalias Em Trilho a Partir De Características De Textura De Imagens Digitais. **Revista Ifes Ciência**, v. 9, n. 1, p. 01–12, 2023.

SAEEDI, S., REZAYI, S., KESHAVARZ, H., & R. NIAKAN KALHORI, S. MRI-based brain tumor detection using convolutional deep learning methods and chosen machine learning techniques. **BMC Med Inform Decis Mak**, v. 23, n. 16, 2023.

SANTOSH KUMAR, P.; SAKTHIVEL, V. P.; RAJU, M.; SATYA, P. D. Brain tumor segmentation of the FLAIR MRI images using novel ResUnet. **Biomedical Signal Processing and Control**, v. 82, 2023. Elsevier Ltd. Acesso em: 8/12/2023.

SANTOS, TATIANY CARVALHO DOS; CARVALHO, CINARA DA CUNHA SIQUEIRA; SILVA, GERUZA CARDOSO DA; DINIZ, THAMARA AMARAL; SOARES, THAÍS EMANUELE; MOREIRA, SÓSTENES DE JESUS MAGALHÃES;

CECON, P. R. Influência do ambiente térmico no comportamento e desempenho zootécnico de suínos. **Revista de Ciências Agroveterinárias**, v. 17, n. 2, p. 241–253, 2018.

SHAIKH, SHAZIA; AKHTER, NAZNEEN; MANZA, R. Medical Image Processing of Thermal Images in Light of Applied Color Palettes. **International Journal of Engineering and Advanced Technology (IJEAT)**, v. 8, n. 6, 2019.

SHARMA, N.; GUPTA, S.; RESHAN, M. S. AL; et al. EfficientNetB0 cum FPN Based Semantic Segmentation of Gastrointestinal Tract Organs in MRI Scans. **Diagnostics**, v. 13, n. 14, 2023.

DA SILVA RODRIGUES, A. V., MARTELLO, L. S., PACHECO, V. M., DE SOUZA SARDINHA, E. J., PEREIRA, A. L. V., & DE SOUSA, R. V. Thermal signature: A method to extract characteristics from infrared thermography data applied to the development of animal heat stress classifier models. **Journal of Thermal Biology**, v. 115, p. 103609, 2023.

SINGH, ONKAR; KASHYAP, KANCHAN LATA; SINGH, K. K. Meshless technique for lung computed tomography image enhancement. **Biomedical Signal Processing and Control**, v. 81, p. 104452, 2023.

SRIVASTAVA, S.; VIDYARTHI, A.; JAIN, S. Analytical study of the encoder-decoder models for ultrasound image segmentation. **Service Oriented Computing and Applications**, 2023. Springer London. Disponível em: <<https://doi.org/10.1007/s11761-023-00373-9>>. .

STEWART, M.; WILSON, M. T.; SCHAEFER, A. L.; HUDDART, F.; SUTHERLAND, M. A. The use of infrared thermography and accelerometers for remote monitoring of dairy cow health and welfare. **Journal of dairy science**, v. 100, n. 5, p. 3893–3901, 2017. *J Dairy Sci.* Disponível em: <<https://pubmed.ncbi.nlm.nih.gov/28259410/>>. Acesso em: 8/12/2023.

TAMMOOR M, NASEER A, KHAN A, Z. K. Skin Lesion Segmentation Using an Ensemble of Different Image Processing Methods. **Diagnostics**, v. 13, n. 16, p. 2684, 2023.

TITTO, C. G.; HENRIQUE, F. L.; PANTOJA, M. H. DE A.; ÇAKMAKÇI, C.; SILVA, P. DOS S. Editorial: Behavior and heat stress. **Frontiers in veterinary science**, v. 10, 2023. *Front Vet Sci.* Disponível em: <<https://pubmed.ncbi.nlm.nih.gov/37388465/>>. Acesso em: 8/12/2023.

TUCKER, B. S., JORQUERA-CHAVEZ, M., PETROVSKI, K. R., CRAIG, J. R., MORRISON, R. S., SMITS, R. J., E KIRKWOOD, R. N. Comparing surface temperature locations with rectal temperature in neonatal piglets under production conditions. **Journal of Applied Animal Research**, v. 51, n. 1, p. 212–219, 2023.

VÁSQUEZ, N.; CERVANTES, M.; BERNAL-BARRAGÁN, H.; RODRÍGUEZ-TOVAR, L. E.; MORALES, A. Short- and Long-Term Exposure to Heat Stress Differently Affect Performance, Blood Parameters, and Integrity of Intestinal Epithelia of Growing Pigs. **Animals**, v. 12, n. 19, p. 1–14, 2022.

WANG, Z.; WANG, S.; WANG, C.; et al. A Non-Contact Cow Estrus Monitoring Method Based on the Thermal Infrared Images of Cows. **Agriculture (Switzerland)**, v. 13, n. 2, 2023. MDPI. Disponível em: <https://www.researchgate.net/publication/368324047_A_Non-Contact_Cow_Estrus_Monitoring_Method_Based_on_the_Thermal_Infrared_Images_of_Cows>. Acesso em: 8/12/2023.

WHITTAKER, AL; MUNS, R.; WANG, D.; MARTÍNEZ-BURNES, J.; HERNÁNDEZ-ÁVALOS, I.; CASAS-ALVARADO, A.; DOMÍNGUEZ-OLIVA, A.; MOTA-ROJAS, D. Assessment of Pain and Inflammation in Domestic Animals Using Infrared Thermography: A Narrative Review. **Animals**, v. 13, p. 2065, 2023.

WILSON, A. N.; GUPTA, K. A.; KODURU, B. H.; et al. Recent Advances in Thermal Imaging and its Applications Using Machine Learning: A Review. **IEEE Sensors Journal**, v. 23, n. 4, p. 3395–3407, 2023. Institute of Electrical and Electronics Engineers Inc. Disponível em: <https://www.researchgate.net/publication/367030994_Recent_Advances_in_Thermal_Imaging_and_its_Applications_using_Machine_Learning_A_Review>. Acesso em: 8/12/2023.

WZIĄTEK-KUCZMIK, D.; NIEDZIELSKA, I.; MROWIEC, A.; et al. Is Thermal Imaging a Helpful Tool in Diagnosis of Asymptomatic Odontogenic Infection Foci—A Pilot Study. **International Journal of Environmental Research and Public Health** **2022**, Vol. 19, Page 16325, v. 19, n. 23, p. 16325, 2022. Multidisciplinary Digital Publishing Institute. Disponível em: <<https://www.mdpi.com/1660-4601/19/23/16325/htm>>. Acesso em: 8/12/2023.

XD ZHANG, X. KANG, L. MA, G. L. Automatic detection method of dairy cow mastitis based on thermal infrared image. **Infrared Physics & Technology**, v. 102, 2019.

XIONG, Y.; LI, G.; WILLARD, N. C.; ELLIS, M.; GATES, R. S. MODELING NEONATAL PIGLET RECTAL TEMPERATURE WITH THERMOGRAPHY AND MACHINE LEARNING. **Journal of the ASABE**, v. 66, n. 2, p. 193–204, 2023. Disponível em: <<https://doi.org/10.13031/ja.14998>>. Acesso em: 8/12/2023.

YAN, X., LIN, B., FU, J., LI, S., WANG, H., FAN, W., ... & JIANG, C. MRSNet: Joint consistent optic disc and cup segmentation based on large kernel residual convolutional attention and self-attention. **Digital Signal Processing**, v. 145, p. 104308, 2023.

ZHANG, F.; DAI, Y.; PENG, X.; WU, C.; ZHU, X.; ZHOU, R.; WU, Y. Brightness segmentation-based plateau histogram equalization algorithm for displaying high dynamic range infrared images. **Infrared Physics e Technology**, v. 134, p. 104894, 2023.

ZHU, Y.; NIE, X.; LI, Y.; NIE, C.; WANG, C.; GAO, Z. A Novel Fault Diagnosis Method for Train Real-Time Ethernet Network Based on Physical Layer Electrical Signal Features. **IEEJ Transactions on Electrical and Electronic Engineering**, v. 18, n. 10, p. 1673–1681, 2023.

CAPÍTULO III

**VISÃO COMPUTACIONAL APLICADA A ANÁLISE DE PADRÕES DO
COMPORTAMENTO DE SUÍNOS EM AMBIENTE CLIMATIZADO**

Visão computacional aplicada a análise de padrões do comportamento de suínos em ambiente climatizado

RESUMO

A observação do comportamento dos suínos como a ingestão de alimentos, de água e repouso são fundamentais para aprimorar o bem-estar desses animais. No entanto, monitorar tais comportamentos pelos métodos tradicionais podem ser desgastantes para os humanos e para os animais interferindo no seu desenvolvimento. A pesquisa objetiva identificar padrões comportamentais de suínos em ambiente climatizado por meio da visão computacional. Foram instaladas microcâmeras nas baias dos animais para a geração de vídeos em um período experimental de 92 dias e foram registrados simultaneamente a temperatura e a umidade do ar. Foram coletadas as variáveis fisiológicas dos animais para identificar se estes estavam ou não sob estresse térmico. Para reconhecer o comportamento de beber, comer, ficar em pé e se deitar dos suínos foi treinado o YOLOv5 e em seguida o modelo foi usado para detectar os animais. Regiões nas imagens correspondentes aos comedouros e bebedouros foram estabelecidas. Para identificar o comportamento alimentar e de ingestão de água, critérios baseados na ocupação da zona de alimentação pela detecção de suínos na posição em pé foram estabelecidos. Os resultados mostraram que o modelo treinado alcançou uma taxa de precisão média de 97,3% e revocação média de 96,1% na detecção dos animais. O modelo exibiu taxas de precisão 97,5% e revocação 97,0% no reconhecimento do comportamento alimentar e do consumo de água dos suínos. A proposta pode ser utilizada em vídeos ou imagens e minimiza a necessidade de intervenção manual, oferecendo um meio eficiente de monitorizar o comportamento dos suínos em ambientes agrícolas e de contribuir para a produtividade das operações de criação de suínos.

Palavra-chaves: Bem-Estar Animal. Reconhecimento Automático. Suinocultura Inteligente. Tecnologia na Produção Suína.

3.1 Introdução

A observação do comportamento dos suínos como a ingestão de alimentos, de água e repouso são fundamentais para aprimorar o bem-estar desses animais (TRINDADE et al., 2023). No entanto, monitorar tais comportamentos pelos métodos tradicionais podem ser desgastantes para os humanos e para os animais interferindo no

seu desenvolvimento (SHAO et al., 2021). Somado a isso Pan et al. (2023) descreveram que à medida que a produção se expande, torna-se inviável observar todas as atividades de cada animal, bem como seu controle diário e individualizado.

Além disso, podem ser falhosas e não retratar com precisão o verdadeiro diagnóstico da saúde dos animais (SHAO et al., 2021). Arablouei et al. (2023a) descreveram que a observação manual e o registro do comportamento animal envolvem esforços significativos e, em determinados casos, podem se tornar inviáveis. Li et al. (2023) relatam que métodos convencionais, tais como a pintura, marcação, uso de brincos de identificação e a aplicação de sistemas de radiofrequência (RFID), demandam recursos humanos e materiais substanciais, o que resulta em uma carga de trabalho considerável e uma eficiência reduzida. Esses métodos segundo Kim et al. (2022) não são adequados para uma suinocultura saudável e precisa.

Sendo assim, esses métodos precisam ser aprimorados para alcançar o desenvolvimento intensivo e sustentável da pecuária, como destacado por Ma et al. (2023). Para substituir esses métodos ou aprimorá-los Liu et al. (2023) citam que os produtores devem investir em soluções precisas e eficazes para o desafio da identificação individual de suínos.

Dessa forma, visando monitorar o comportamento de suínos, muitos pesquisadores desenvolveram pesquisas com sistemas de monitoramento automatizado que empregam sensores, como câmeras sensíveis ao infravermelho para realizar o acompanhamento em tempo real das atividades dos suínos (COSTA et al., 2013). No entanto, Hao et al. (2022) relatam que esses tipos de métodos baseados em sensores são suscetíveis a danos por colisão, o que pode levar a uma identificação imprecisa e causar estresse aos animais, tanto em termos mentais quanto físicos. Outros pesquisadores utilizaram sistemas de vigilância com câmeras para monitorar os animais de forma automática (HAN et al., 2023).

Kim et al. (2022) descreveram que mais recente as técnicas de aprendizado profundo de máquina têm sido amplamente utilizadas para aplicações da visão computacional (reconhecimento de objetos, classificação de objetos e detecção de objetos), como o aprendizado de máquina baseadas em Redes Neurais Profundas.

Zhuang et al. (2022) desenvolveram um modelo para o reconhecimento dos comportamentos de alimentação e ingestão de água em suínos, fazendo uso de três modelos distintos: VGG19, Xception e MobileNetV2 e alcançaram uma taxa de recuperação superior a 97%. Wang et al. (2023) apresentaram uma rede ResNAM

aprimorada para reconhecer faces de suínos e obtiveram bons resultados, com um aumento de 3% na precisão do reconhecimento.

Yang et al. (2018) para reconhecer o comportamento alimentar e o índice de ocupação de 4 porcas, usaram uma Rede Neural Convolutiva de Região Mais Rápida (Faster R-CNN) e obtiveram bons resultados.

Porém, essas técnicas de aprendizado profundo requerem muitos parâmetros e, exigem altos custos computacionais para realizar treinamento e testes (KIM et al., 2022). Nepal e Eslamiat (2022) citam que durante o treinamento com redes convolucionais usando imagens é necessária uma capacidade de Unidades de Processamento Gráfico (GPU) muito alta. Hao et al. (2023) citam que devido a essas exigências computacionais os métodos fundamentados em aprendizado profundo restringem a sua aplicação viável em dispositivos de memória e capacidade reduzidas.

Paralelamente, Khan et al. (2023) citam que dentre essas técnicas de visão computacional usando rede neural convolutiva, surgiu a ferramenta YOLO (*You Only Look Once*) para detecção de objetos, sendo mais rápida de treinar e mais eficiente, além disso pode ser implementada no *Google Colaboraty (colab)* usando uma GPU gratuita. Além do mais, de acordo com Sozzi et al. (2022) o YOLOv5 foi desenvolvido com linguagem *Python*, o que pode ser uma outra vantagem. E ainda o *framework* nativo do YOLOv5 é o *PyTorch*, que permite um treinamento mais rápido (JOCHER et al., 2021).

Segundo Witte e Gómez (2022) a técnica YOLO para detecção de objetos é realizada em um único estágio diretamente na imagem de entrada, apresentando assim, um tempo de execução mais rápido do que a detecção de objetos em dois estágios. De acordo com Gonzaga et al. (2023), o YOLOv5 adota uma abordagem onde uma única rede convolutiva é empregada para efetuar previsões simultâneas, tanto das caixas delimitadoras (tratando a detecção de objetos como um problema de regressão) quanto das probabilidades associadas às classes dos objetos detectados (atuando como um classificador).

Na literatura, muitas pesquisas foram desenvolvidas na área da pecuária suína utilizando o algoritmo YOLOv5. Zhou (2022a) utilizou YOLOv5 para detectar e realizar a contagem de suínos em comedouros e bebedouros em tempo real. Huang et al. (2023a) utilizaram o YOLOv5 para realizar a detecção e a contagem de suínos em abatedouros. Lai et al. (2023) utilizaram o YOLOv5 para detectar suínos em diferentes sistemas de iluminação e de oclusão. Nie et al. (2024) usaram o YOLOv5 para detectar emoções em rostos de suínos.

Nos últimos anos, tecnologias avançadas, como a tecnologia de detecção e a internet das coisas, têm experimentado um rápido desenvolvimento, sendo capaz de adquirir eficazmente informações sobre o estado fisiológico, movimentação, comportamento dos animais e informações do ambiente externo, como relatado por Yin et al. (2023).

A maioria dos trabalhos utilizando técnicas de aprendizado profundo vem estudando o comportamento dos animais, porém, não são levados em consideração a associação do conforto térmico do ambiente com o etograma do comportamento destes, uma vez que eles são influenciados pelo microclima local. Dessa forma, esse trabalho contribui para pesquisadores, empreendedores, no sentido de apresentar um programa computacional capaz de associar o ambiente de produção com o comportamento do animal, sem interferir nas atividades normais dos animais utilizando imagens ou vídeos de câmeras de monitoramento 2D de baixo custo.

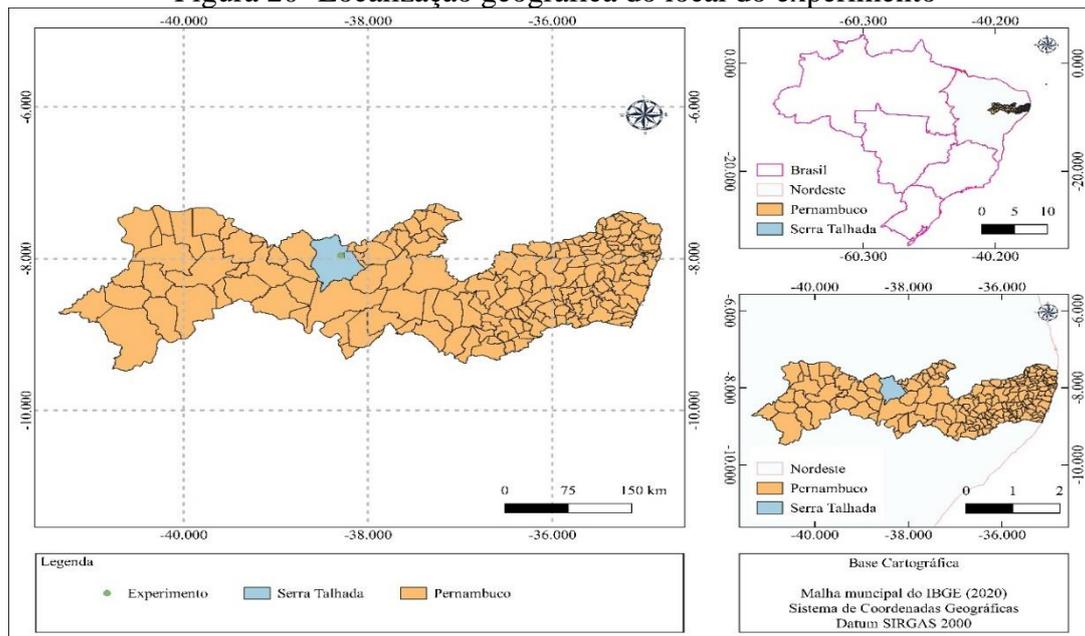
Sendo assim, a pesquisa objetivou identificar padrões comportamentais de suínos em ambiente climatizado por meio da visão computacional.

3.2 Material e métodos

3.2.1 Localização do experimento

O presente estudo foi conduzido no Biotério de Experimentação com Suínos, situado no campus da Universidade Federal Rural de Pernambuco (UFRPE), localizado na cidade de Serra Talhada, na região do sertão do estado de Pernambuco, Brasil. A localização geográfica do município é delimitada pelas coordenadas latitude 7°57'20.60"S e longitude 38°17'45.22" W, conforme ilustrado na Figura 20.

Figura 20- Localização geográfica do local do experimento



De acordo com a classificação climática de Köppen, a região é caracterizada pelo clima do tipo BSw_h, que representa um clima quente e seco (BEZERRA et al., 2020). A temperatura média anual em Serra Talhada é de 24,8 °C, e a precipitação média anual é de 642,1 mm. A umidade relativa do ar na região é próxima de 62,5%. Essas condições climáticas resultam em uma demanda atmosférica de 1.800 mm por ano, com um déficit de 1.143 mm por ano (FERRAZ JARDIM et al., 2019b).

3.2.2 Instalações

A pesquisa foi conduzida em um galpão experimental com uma área total de 330 m². O galpão estava posicionado na direção leste-oeste, visando maximizar a exposição solar e otimizar as condições ambientais. As baias localizadas dentro do galpão foram construídas com materiais de alvenaria, com piso de concreto e apresentavam dimensões de 2 x 3 m cada. O telhado tinha uma inclinação unidirecional e era coberto com telhas cerâmicas. Além disso, as baias eram equipadas com comedouros e bebedouros adequados para atender às necessidades dos suínos ao longo do experimento.

3.2.3 Experimento

A coleta de dados ocorreu ao longo de 92 dias, no período compreendido entre agosto e dezembro de 2017. O experimento foi conduzido em conformidade com as diretrizes éticas e recebeu aprovação da Comissão de Ética no Uso de Animais da

Universidade Federal Rural de Pernambuco (CEUA/UFRPE). O protocolo de aprovação utilizado foi o n° 23082.021090/2016-81, garantindo que todas as medidas necessárias para o bem-estar e cuidado dos animais fossem seguidas durante a pesquisa.

Foram utilizados 18 suínos, incluindo machos e fêmeas, distribuídos em grupo de 3 em cada baia. Os animais foram selecionados a partir de um grupo disponível no biotério de experimentação da universidade, da linhagem comercial $\frac{3}{4}$ Duroc e $\frac{1}{4}$ Pietrain em fase de crescimento. Os suínos foram alimentados duas vezes ao dia, uma vez pela manhã e outra à tarde e podiam beber a qualquer hora.

Foram utilizadas 6 baias no estudo, três com sistema de climatização, equipadas com climatizadores para estudar os efeitos do resfriamento evaporativo adiabático nos animais e outras 3 baias sem nenhum sistema de climatização (sob ventilação natural), permitindo a análise dos animais em condições de ventilação natural. Os climatizadores utilizados nas baias possuíam uma vazão média de 3 L/h, com motores independentes e hélice girando a uma velocidade de 1.750 RPM e disco central a 3.450 RPM.

3.2.4 Coleta de variáveis

3.2.4.1 Variáveis meteorológicas

Para caracterizar o microclima do ambiente interno das instalações foram registradas a temperatura do ar (T_{bs} , em °C), a umidade relativa do ar (UR, em %) e a temperatura de globo negro (T_g , em °C) durante os 92 dias de monitoramento. Os registros dos elementos meteorológicos foram realizados utilizando um datalogger do modelo U12-012 (Onset Computer Corporation Bourne, MA, EUA), da marca HOBO®, durante o dia e a noite. O posicionamento do instrumento seguiu as recomendações de Barbosa Filho et al. (2007), que sugerem que os equipamentos sejam instalados preferencialmente na região central do galpão.

Essas variáveis foram coletadas dentro das baias, por meio do *datalogger* e no ambiente externo, utilizando um abrigo meteorológico. Ambos os equipamentos foram posicionados a uma altura de 1,50 m, visando obter informações representativas das variações entre os tratamentos.

3.2.4.2 Variáveis fisiológicas

Com o objetivo de avaliar o impacto dos diferentes sistemas de climatização no conforto térmico dos animais, foram coletadas variáveis fisiológicas, temperatura retal

(TR), frequência respiratória (FR) e temperatura superficial da pele (TSP). Essas medições foram realizadas uma vez por semana, ao longo de todo o período experimental.

A TR foi obtida utilizando um termômetro clínico digital inserido no reto dos animais. A FR foi medida contando-se os movimentos do flanco durante 15 segundos, utilizando um cronômetro e em seguida calculando-se o número de movimentos por minuto. A TSP dos suínos foi coletada utilizando um termovisor do modelo FLIR i60. Esse equipamento capturou imagens termográficas de todo o corpo dos animais. As imagens foram adquiridas a uma distância de 1 metro do animal, seguindo a recomendação de Moreira et al. (2021), que afirmam que essa distância é suficiente para enquadrar todo o corpo do suíno. Além disso, as configurações do termovisor foram ajustadas para uma emissividade de 0,98, que segundo Titto e Ricci (2023) é apropriada para tecidos biológicos e vem sendo utilizada em pesquisas com suínos. Além disso, foram inseridos os valores de temperatura e umidade relativa do ar do momento do registro das imagens como parâmetros para correção da temperatura das imagens térmicas, permitindo a análise das relações entre as temperaturas corporais dos animais e o ambiente em que estavam inseridos.

3.2.4.3 Variáveis comportamentais

Para monitorar o comportamento dos animais foram registrados vídeos de 30 minutos gravados em 25 quadros s^{-1} (FPS) com largura de quadro de imagem de 640 pixels e altura de quadro de 360 pixels. As gravações foram realizadas uma vez por semana, durante um período de 24 horas, ao longo de todo o experimento (92 dias). A primeira semana de análise foi excluída, pois nesse período os animais estavam se adaptando aos ambientes, conforme sugerido por Kiefer et al. (2010), resultando em 11 semanas, totalizando 12 dias de registros de vídeos de 24 horas resultando em 288 horas de vídeos.

Para o registro dos vídeos foram utilizadas microcâmeras (VMD S3020 IR, com ângulo de visão de 90°) equipadas com lente de 3,6 mm. Essas câmeras foram instaladas no interior das baias, a uma altura de 3,0 metros do piso, posicionadas de maneira adequada para monitorar os animais.

A análise dos comportamentos dos animais foi realizada com base em um etograma adaptado de Pandorfi e Silva (2005), Kiefer et al. (2010) e Massari et al. (2015).

A Tabela 11 apresenta as classes de comportamentos analisados, os rótulos inseridos para cada classe as observações referentes aos comportamentos avaliados.

Tabela 11- Comportamento de suínos.

Comportamentos	Rótulos	Descrição
Bebendo	Drinking	Suíno ingerindo água no bebedouro
Comendo	Eating	Suíno ingerindo alimentos no comedouro
Deitado	Lying	Suíno deitado ou dormindo sobre o piso
Em pé	Standing	Suíno se locomovendo ou investigando

Fonte: Adaptado de Pandorfi e Silva (2005) e Massari et al. (2015).

Esse etograma permitiu quantificar a frequência e a porcentagem de tempo despendido em cada comportamento listado, de acordo com seus respectivos tratamentos.

3.2.5 Procedimento metodológico

3.2.5.1 Avaliação do conforto térmico dos animais

A avaliação do ambiente térmico foi conduzida mediante a análise das condições de temperatura e umidade relativa do ar, observando as faixas necessárias para atender às exigências dos animais, conforme apresentado na Tabela 12.

Tabela 12- Temperaturas e umidades relativas ótimas e críticas para suínos

Suínos	Temperaturas ótimas (°C)		Temperaturas Críticas (°C)		Umidades relativas (%)	
	Máx.	Mín.	Máx.	Mín.	Ótima	Crítica
Crescimento	21	18	30	8	70	<40 e >90
Terminação	18	15	27	5		

Fonte: Baêta & Souza (2010) e Sulzbach et al. (2020).

A avaliação do conforto térmico dos animais incluiu a análise das variáveis fisiológicas, como a temperatura retal e a frequência respiratória, conforme detalhado na Tabela 13.

Tabela 13- Frequência respiratória e Temperatura retal

Suínos	Frequência Respiratória (mov·min ⁻¹)		Temperatura Retal (°C)	
Categoria	Normal	Estresse térmico	Normal	Estresse térmico
Adultos	≤ 60	>60	≤ 39,3	>39,3

A caracterização térmica nas instalações foi conduzida utilizando o Índice de Temperatura de Globo Negro e Umidade (ITGU), seguindo a metodologia de Alves et al. (2023), que elaboraram o ITGU para suínos em terminação (Tabela 14).

Tabela 14- Classificação de ITGU para suínos

Categoria	Intervalo
Estresse	ITGU \leq 67
Conforto	68 < ITGU \leq 74
Alerta	75 < ITGU \leq 76
Emergência	ITGU > 76

O ITGU seguiu a metodologia desenvolvida por Buffington et al. (1981) integrando dados da temperatura de globo negro e da umidade ambiental, sendo expresso pela equação 1:

$$ITGU = T_{gn} + 0,36T_{po} + 41,5 \quad (1)$$

em que T_{gn} é a temperatura de globo negro ($^{\circ}\text{C}$) e T_{po} é a temperatura do ponto de orvalho ($^{\circ}\text{C}$).

Os valores de temperaturas (T) e umidades (UR) foram utilizados para estimar a temperatura do ponto de orvalho pela equação 2.

$$T_{po} = \frac{c \cdot \gamma(T, UR)}{b - \gamma(T, UR)} \quad (2)$$

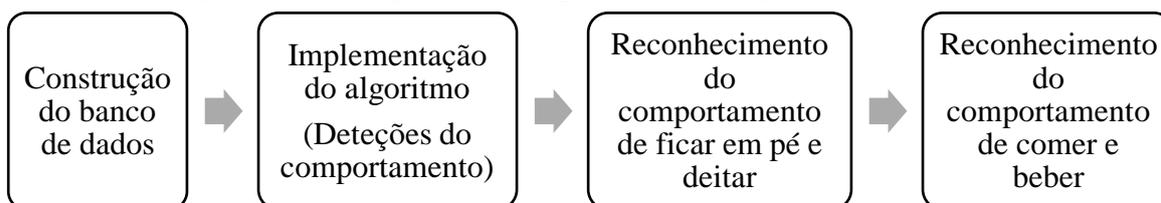
$$\gamma(T, UR) = e_s(T) * \frac{(UR)}{100}$$

em que, T_{po} é a temperatura do ponto de orvalho, $\gamma(T, UR)$ é a relação entre a pressão de vapor saturado e a pressão de vapor atual, b constante de valor 238.88 e c constante de valor 17.368 e $e_s(T)$ é a pressão de vapor saturado a uma dada temperatura T.

3.2.5.2 Monitoramento do comportamento dos animais

O monitoramento dos comportamentos de ficar em pé e se deitar, comer e beber foram desenvolvidos em etapas e estão apresentados no fluxograma da Figura 21 a seguir.

Figura 21- Fluxograma da Etapa de Monitoração dos Animais



3.2.5.2 Preparação da Base de Dados

Foram selecionados 18 vídeos do experimento, cada um com duração de 30 minutos e uma taxa de 25 FPS. Dentre esses vídeos, 9 são provenientes das baias equipadas com climatizadores, enquanto os outros 9 são das baias sem climatizadores.

Esses vídeos foram submetidos à plataforma online *google colab* para a extração dos frames por meio de códigos.

Após a extração das imagens, realizou-se uma observação manual para identificar as que apresentavam diferenças comportamentais significativas. Verificou-se que muitas imagens eram praticamente idênticas, pois correspondiam a frames sequenciais dos vídeos. A partir disso, foi realizada uma seleção manual das imagens que apresentavam comportamentos distintos entre si, seguindo o procedimento descrito por Adorno et al. (2023) e a recomendação ressaltada por Jocher et al. (2021) ao qual sugerem que a diversidade da base de dados é uma característica essencial e garante a capacidade de generalização do algoritmo YOLOv5.

Após a aquisição das imagens, a preparação do conjunto de dados foi conduzida em três etapas: anotação dos dados com seus rótulos correspondentes, pré-processamento dos dados e aplicação da técnica de aumento de dados para criar imagens sintéticas.

A etapa de anotação consistiu na delimitação através de *bounding boxes* (caixas delimitadoras) na imagem na posição onde o objeto de interesse se encontra e, o apontamento da classe à qual ela pertence. Foi utilizado a plataforma *online Roboflow*, tal plataforma também foi utilizada no trabalho de Santos e Quarto (2022) para anotação de imagens em uso de redes neurais convolucionais. Na plataforma, as imagens foram abertas individualmente e, em cada uma delas, foram desenhadas manualmente caixas retangulares delimitando cada suíno dentro da imagem. Cada caixa foi rotulada com uma classe indicando o comportamento do animal.

Os rótulos anotados foram salvos no formato YOLOv5 *pytorch*. Nesse formato, cada objeto na imagem é descrito por meio de uma localização de *bounding box* normalizada da seguinte maneira (Eq. 3):

$$class_id, x_axis_value, y_axis_value, width, heigh \quad (3)$$

em que a denominação *class_id* corresponde a classe; *x_axis_value* e *y_axis_value* correspondem a coordenada x e y do centro da *bounding box*; *width* e *heigh* correspondem a largura e à altura da *bounding box* (CHANG e ZHANG, 2022).

Essas informações foram armazenadas em um arquivo editável com o nome correspondente de cada imagem e em uma etapa subsequente as coordenadas dos pixels das classes comendo e bebendo foram utilizadas. As anotações de todas as imagens demandaram cerca de quatro semanas para serem concluídas. De acordo com Han et al.

(2023) para anotar imagens de suínos em baias coletivas, demora-se cerca de 5 minutos por imagem. Cada animal foi analisado como uma instância para o treinamento do algoritmo.

Como etapas de pré-processamento foram aplicadas orientação automática para evitar erros com a orientação da imagem; as imagens foram redimensionadas para 416 x 416 pixels para padronização do tamanho das imagens ao padrão de entrada do YOLOv5 e para corrigir o contraste foi aplicado equalização adaptativa. Nessa fase, as classes comendo e bebendo foram reclassificadas para se unirem à categoria em pé.

Como técnicas de aumento de dados, foram aplicados o espelhamento de imagens, as quais as imagens são viradas de forma horizontal na direção esquerda/direita e vertical na direção para cima/baixo e a rotação de imagens para 90° no sentido horário, anti-horário e de cabeça para baixo.

Posteriormente, as imagens foram divididas em conjuntos distintos: 80% (4000 amostras) foram alocadas para o conjunto de treinamento, 10% (500 imagens) compuseram o conjunto de validação, e o restante 10% (500 amostras) foram destinados ao conjunto de teste. Esse procedimento totalizou 5000 imagens e 15000 instâncias utilizadas no estudo.

Essas informações estão em concordância com as orientações de Jocher et al. (2021), que recomendam a utilização de conjuntos de dados diversificados, incluindo diferentes condições de iluminação, como manhã, tarde e noite e dados de diferentes câmeras. As imagens obtidas foram analisadas e classificadas em comportamentos específicos, com base em estudos anteriores conduzidos por Pandorfi e Silva (2005), Kiefer et al. (2010) e Massari et al. (2015).

3.2.5.3 Implementação do algoritmo

O treinamento foi realizado no ambiente do *Google Colab*, utilizando o notebook de código aberto disponibilizado pelo desenvolvedor do YOLOv5 no link <https://github.com/ultralytics/yolov5>.

A *Google* desenvolveu o *Google Colaboratory*, conhecido como *Colab*, para simplificar e disseminar o ensino e a pesquisa em aprendizado de máquina. O *Colab* configura-se como um ambiente virtual hospedado na nuvem da *Google* e proporciona acesso gratuito a um ambiente de *Jupyter notebook*. O *Colab* oferece duas vantagens para pesquisas: uma por meio do *Google Research* que disponibiliza várias unidades de processamento gráfico (GPUs) gratuitamente por 4 horas por dia, por meio da nuvem. A

outra vantagem é que o *Google Colab* permite que os usuários escolham entre utilizar a unidade central de processamento (CPU) ou uma unidade de processamento gráfico (GPU) na nuvem ao se conectar a um notebook. Entre os modelos de GPU disponíveis estão a Tesla V100, Tesla K80, Tesla T4, Tesla P40, porém, o modelo de GPU atribuído não é selecionado pelo usuário, mas sim determinado pela demanda e disponibilidade dos dispositivos no momento da conexão.

Inicialmente, foi criada uma pasta no drive associada ao e-mail para acomodar os arquivos resultantes do treinamento. Em seguida, o projeto foi configurado no ambiente do *Google Colab* por meio de acesso à plataforma de pesquisa.

Para dar início ao treinamento, conectou-se a uma GPU e habilitou a *API Compute Unified Device Architecture (CUDA)*, o que permitiu o processamento paralelo e contribuiu para uma execução mais eficiente e rápida do treinamento do modelo.

Em seguida, o YOLOv5 foi clonado diretamente do repositório do desenvolvedor no *GitHub*, juntamente com todas as suas dependências e requisitos necessários. Após a implementação do YOLOv5, procedeu-se o *download* do conjunto de dados diretamente do *Roboflow* para o ambiente colaborativo (*Colab*). Em seguida, realizou-se a configuração do arquivo *.yaml* para contemplar o número de 4 classes, visto que a arquitetura original do YOLO é padronizada para a classificação de 80 categorias. O treinamento do modelo YOLOv5 foi conduzido utilizando o framework *PyTorch*.

Dentre as quatro variantes de modelos disponíveis, YOLOv5s (modelo pequeno), YOLOv5m (modelo médio), YOLOv5l (modelo grande) e YOLOv5x (modelo extra grande), optou-se por avaliar o modelo pequeno, médio e grande para reduzir o custo computacional.

Antes de iniciar o treinamento, os hiperparâmetros foram otimizados utilizando o método dos algoritmos genéticos. Esse processo, conforme sugerido por Jocher et al. (2021), envolveu a criação de um cenário base, a partir do qual os hiperparâmetros foram otimizados. O cenário base foi submetido a 10 épocas de treinamento, em conformidade com a recomendação de Jocher et al. (2021). Para a evolução dos hiperparâmetros, utilizou-se a mutação com uma probabilidade de 80% e uma variância de 0,04, gerando novos descendentes através da combinação dos melhores pais de todas as gerações anteriores. A prole com a maior aptidão foi preservada a cada geração do processo evolutivo e utilizada para treinar o algoritmo. Os hiperparâmetros obtidos foram taxa de aprendizado inicial de 0,0001, taxa de momentum de 0,97 e a taxa de decaimento do aprendizado 0,95. Outros hiperparâmetros foram ajustados, um tamanho de lote de 16

imagens e o número de iterações para 100 épocas. O treinamento do modelo foi realizado sequencialmente, seguindo os passos disponíveis no notebook adotado, utilizando os hiperparâmetros obtidos na etapa anterior.

3.2.5.3.1 Avaliação do desempenho do modelo

O desempenho do modelo foi avaliado utilizando métricas comumente empregadas em aprendizado profundo, seguindo a abordagem adotada por Fan et al. (2023). Isso inclui métricas como precisão (P), recall (R), precisão média (AP) e mAP (média da precisão de AP de todas as classes). VP (verdadeiros positivos), é o número de suínos identificados corretamente, enquanto FP (falsos positivos), é o número de suínos identificados incorretamente e FN (falsos negativos) é o número de indivíduos que o modelo não conseguiu identificar. E AP é a precisão média da precisão. As equações dessas métricas estão expressas matematicamente nas equações a seguir (Eq. 4 a 6).

$$\text{Precisão (P)} = \frac{VP}{VP + FP} \quad (4)$$

$$\text{Recall (R)} = \frac{VP}{VP + FN} \quad (5)$$

$$\text{mAP} = \frac{1}{n} \sum_{i=1}^n AP_i \quad (6)$$

Para avaliar o desempenho do método proposto para o comportamento de beber e comer, foram selecionados os vídeos após o horário de fornecimento de ração. Um vídeo de cada baía pela manhã e outro na parte da tarde. Para o comportamento de beber os vídeos observados com essa atividade foram divididos em vários segmentos.

Foram utilizados três métricas, conforme indicado por Shi et al. (2023), Wang et al. (2023) e Escobar-Amado et al. (2023). Essas métricas incluem o Erro Médio Absoluto (EMA) que significa a medida da diferença absoluta entre as variáveis previstas e as reais, a Raiz do Erro Médio Quadrático (REMQ) que medem a dispersão dos erros em relação à média e o coeficiente de determinação (R^2) que reflete a qualidade do ajuste dos modelos aos dados e quanto mais próximo de 1, mais preciso o modelo. A análise dessas métricas levou em consideração as caixas verdadeiras e os resultados das interseções entre as detecções do modelo e as regiões de interesse. Matematicamente, essas métricas são expressas pelas Equações 7, 8 e 9.

$$MAE = \frac{1}{n} * \sum_{1-n}^n |\gamma_{True} - \hat{Y}_{pred}| \quad (7)$$

$$RMSE = \sqrt{\frac{1}{n} * \sum_{1-n}^n (\gamma_{True} - \hat{Y}_{pred})^2} \quad (8)$$

$$R^2 = 1 - \frac{\sum_{1-n}^n (\gamma_{True} - \hat{Y}_{pred})^2}{\sum_{1-n}^n (\gamma_{True} - \bar{y})^2} \quad (9)$$

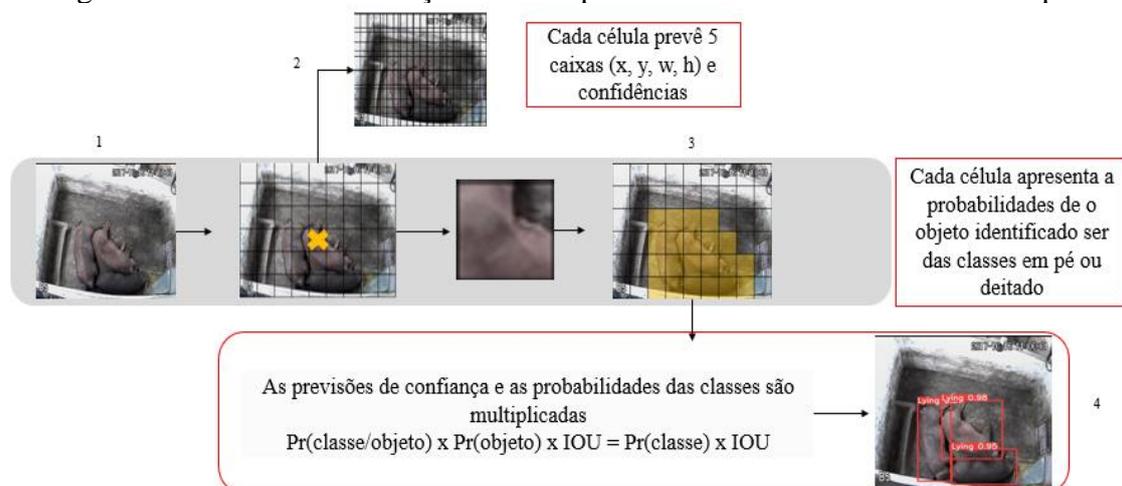
em que: n = número de amostras do conjunto de teste, γ_{True} = valor real, \hat{Y}_{pred} = valor previsto e \bar{y} e a média das observações.

Para verificar se existe diferença significativa no desempenho das diferentes versões do modelo YOLO (YOLOv5m, YOLOv5s e YOLOv5x), utilizou-se o teste de hipótese, análise de variância (ANOVA). Para a hipótese de os desempenhos médios dos modelos serem iguais, o valor-p foi calculado e comparado ao nível de significância de 5%.

3.2.5.4 Reconhecimento da ingestão de ficar em pé e se deitar

O comportamento de ficar em pé e se deitar foi realizado após o modelo treinado, onde foi submetido uma imagem para inferência, conforme apresentado na Figura 22.

Figura 22. Processo de detecção dos comportamentos de deitar-se e ficar em pé



A partir dessa imagem a rede neural do modelo dividiu-a em 19 x 19 regiões, conforme demonstrado etapa 1 na Figura 22. Cada região foi responsável por prever 5 caixas, com a localização dos animais (x, y, w, h) e as confidências de cada caixa conter

um animal do comportamento de ficar em pé ou se deitar (etapa 2 da Figura 22). Dessa forma, esse processo forneceu um valor de probabilidade para cada uma das possíveis classes que o algoritmo foi treinado a encontrar. Boa parte das caixas detectadas, possuem um grau de confiança muito baixo.

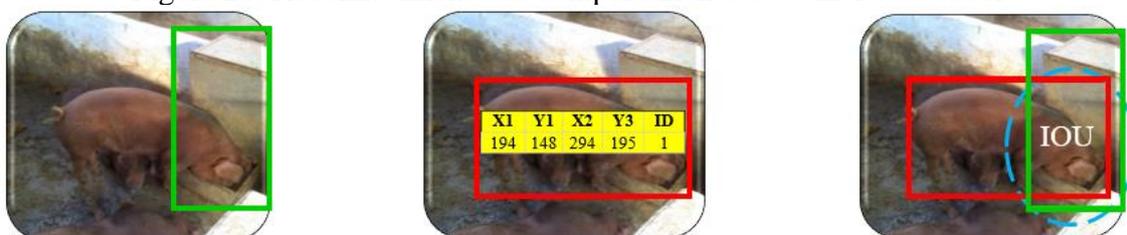
Para eliminar a maioria das caixas foi atribuído um limiar de confiança de 70%, para que todas as caixas que apresentassem valores inferiores fossem removidas e ficassem apenas as de maiores valores, conforme etapa 3 (Figura 22). E por fim as caixas que ficaram sobre a imagem são as responsáveis pela detecção.

3.2.5.5 Reconhecimento da ingestão de alimentos e de água

Para o reconhecimento do comportamento de comer e beber dos suínos foi adotado o mesmo critério utilizado no estudo conduzido por Alameer et al. (2020), em que considerou um porco se alimentando, quando sua cabeça está dentro de um comedouro.

Como os suínos comem e bebem em comedouros e bebedouros foram delimitadas essas regiões em cada imagem utilizando a biblioteca *OpenCV*. Dessa forma, foi feita uma correlação dos animais com essas regiões de interesse. O comportamento alimentar está correlacionado com o comedouro e o comportamento de beber com o bebedouro. Diante da situação em que o comedouro possa estar vazio e, os animais explorarem essa região, a avaliação do comportamento alimentar foi analisada apenas no horário da distribuição da ração. O reconhecimento do comportamento de comer e de beber estão apresentados na Figura 23.

Figura 23. Reconhecimento do comportamento de comer e de beber



Foram delimitados a região do comedouro e do bebedouro. Posteriormente, por meio das detecções realizadas pelo modelo YOLOv5 na etapa anterior, foram capturadas as coordenadas das caixas delimitadoras associadas à classe em pé, já que os suínos ficam em pé enquanto comem ou bebem. Em etapa subsequente, essas coordenadas foram incorporadas a um código desenvolvido em linguagem *Python*, destinado a analisar o comportamento alimentar dos animais. Quando uma caixa delimitadora rotulada como

em pé se cruza com os comedouros, é possível que ocorra o comportamento alimentar, quando se cruza com os bebedouros é possível que ocorra a ingestão de água. Ou seja, a imagem é inserida para o modelo identificar os animais. O modelo detecta os animais e os delimita com as caixas delimitadoras (cor vermelho) (Figura 24). O comportamento alimentar ocorre quando as caixas delimitadoras cruzam as regiões de interesse (cor verde) (Figura 24), combinado com a horário de fornecimento de ração, têm-se o reconhecimento do comportamento alimentar. Quando cruza os com os bebedouros tem se a ingestão de água, tal como na Figura 24.

Figura 24. Reconhecimento do comportamento de comer e beber



Como existem situações que os animais se aproximam das regiões de interesse e não ingere alimentos e água, foi sugerido uma medida da ocupação da zona de alimentação pelos suínos detectados, indicando a porcentagem da área total destinada à alimentação ou bebida que está efetivamente sendo utilizada por essa parte específica dos animais. Neste procedimento metodológico, foi determinado a Ocupação das Áreas (OC) de interesse pelos retângulos delimitadores detectados pelo modelo. O cálculo da proporção da área da zona de alimentação que está sendo ocupada pelas caixas delimitadoras dos suínos, foi realizado utilizando a Equação 10 como referência.

$$OC = \frac{\text{Deteções do modelo } \Omega \text{ região de interesse}}{\text{Região de interesse}} \quad (10)$$

em que o numerador se refere à região onde os suínos e a zona de alimentação se sobrepõem, ou a parte específica da zona de alimentação que está sendo ocupada pelas

caixas delimitadoras dos suínos. Enquanto no denominador têm-se a área total destinada à alimentação dos suínos.

Foram extraídos segmentos de 5 min dos vídeos de 30 minutos após o fornecimento de ração e foram adquiridos a quantidade de quadros com o consumo de alimentos, em seguida foi obtido o tempo de ocupação no comedouro. Para avaliar o desempenho do reconhecimento do comportamento de comer e beber foi calculado a precisão e o recall.

Dessa forma, o monitoramento dos comportamentos dos animais foi realizado considerando as saídas automáticas do YOLOv5, que forneceram de forma automática as informações das detecções dos suínos, incluindo as coordenadas das caixas delimitadoras, o número de animais detectados, a classe de comportamento, o tempo de processamento de cada frame (tp), o tempo de inferência (ti) e o tempo de supressão não máxima (tsnm) realizado em cada frame. Dessa forma, foi possível realizar a contagem dos animais, as atividades em cada frame do vídeo e o tempo despendido em cada atividade de forma automática.

Para quantificar o tempo das atividades de ficar em pé e se deitar, empregou-se o número total de frames e o somatório das informações fornecidas pelo modelo, incluindo o tempo de processamento (tp), o tempo de inferência (ti) e o tempo de supressão não máxima (tsnm) para cada frame de acordo com a equação 11 para obter a taxa de frames por segundo (FPS) alcançada pelo modelo. Em seguida, calculou-se o tempo para cada uma das classes observadas pela Equação 12.

$$FPS = \frac{1000}{(tp+ti+tsnm)} \quad (11)$$

$$\text{Tempo (H)} = \frac{FPS}{(3600)} \quad (12)$$

Os resultados foram comparados com o tempo de observação visual para cada uma das atividades de ficar em pé (andando e investigando) e deitado (dormindo e deitado), durante todo o período analisado.

Para o comportamento de comer e beber, o tempo de alimentação e de ingestão de água foi contabilizada pela Intersecção sobre União (IOU) das caixas delimitadora dos animais com a dos comedouros e bebedouros. Para quantificar a duração dessas interseções, registrou-se o tempo em número de frames nos quais as áreas dos

comedouros e bebedouros estavam ocupadas com as caixas delimitadoras dos animais em pelo menos 50% do retângulo correspondente às atividades na posição em pé.

O processo de análise manual foi acompanhado dos vídeos e registrados manualmente as atividades realizadas pelos animais como em pé, incluindo as atividades desenvolvidas nessa postura como beber, comer, andar e investigar. E o comportamento de deitar considerando os animais deitados e dormindo. Foi anotado o tempo que cada animal gastou em cada atividade. Posteriormente, os dados foram tabulados no Programa Microsoft Excel 2016 e confeccionados gráficos.

3.3 Resultados e discussão

3.3.1 Análise do ambiente dos animais

Os resultados dos parâmetros estatísticos descritivos das variáveis ambientais coletadas para cada cenário analisado, durante o período experimental, são apresentados na Tabela 15.

Tabela 15. Temperaturas e Umidades Relativa do Ar nas instalações

Tratamentos	Climatizado		Não climatizado	
Parâmetros	T ar (°C)	UR (%)	T ar (°C)	UR (%)
Média	22,59	81,99	30,43	54,62
Mínima	21,02	70,30	24,56	46,62
Máxima	24,87	85,73	33,52	74,63

* Tar = Temperatura do ar e UR = Umidade relativa

Nas instalações, observou-se que a temperatura segue um padrão cíclico ao longo do dia, atingindo o seu valor máximo durante a tarde e mínimo pela manhã. Por outro lado, a umidade relativa do ar expressa variação inversamente proporcional, registrando seu mínimo quando a temperatura alcança o seu pico e vice-versa. Esses padrões foram documentados na Tabela 15. Esta observação também foi corroborada pela pesquisa de Campos et al. (2023), que, ao estudar o conforto térmico de bezerros em clima tropical, observou esse mesmo padrão de temperaturas mais elevadas com menor umidade relativa do ar durante a tarde e menos elevadas pela manhã, com umidade mais alta.

As médias de registros meteorológicos coletados das instalações dos animais durante o período experimental foram temperatura mínima de 21,02°C, temperatura máxima de 24,87°C, umidade relativa mínima de 70,30 e umidade relativa máxima de 85,73%.

A temperatura média observada no ambiente com climatizador foi de 22,59°C. Segundo Baêta e Souza (2010) a temperatura do ar ideal para suínos nas fases de crescimento e terminação está entre os limites de 18 a 21°C. Para Oliveira et al. (2019) os valores de temperatura do ar considerado como confortáveis estão entre 18 e 25°C. No presente estudo, as instalações zootécnicas equipadas com climatizadores proporcionaram condições confortáveis aos animais, as variáveis analisadas de temperatura de bulbo seco não excederam a faixa limite conforme proposto, por Baêta e Souza (2010) e Oliveira et al. (2019), enquadrando o ambiente dentro da zona considerada termoneutra para os animais na fase de crescimento e terminação. Os resultados obtidos nesse trabalho são próximos aos encontrados na pesquisa conduzida por Kiefer et al. (2009) que encontraram valores de temperatura entre 18 e 26°C para suínos em crescimento em ambientes climatizados.

A umidade relativa do ar média para o ambiente com climatizadores foi de 81,99%. A umidade relativa do ar média nesse estudo excedeu a faixa ideal entre 50 e 70% considerada por Baêta e Souza (2010) para suínos nessa fase de crescimento e terminação. Sulzbach et al. (2020) também consideram a umidade relativa do ar ótima para suínos na faixa de 50 a 70%.

Os suínos quando submetidos a ambiente termoneutros, segundo Zhang et al. (2020) não necessitam de gasto energético adicional para regular sua temperatura corporal e suas funções produtivas ocorrem de maneira ideal, livre de estresse e dessa forma os animais apresentam melhores desempenhos produtivos.

Nas baias com ventilação natural, a temperatura mínima registrada foi de 24,56°C e a umidade relativa do ar mínima foi de 46,62%. A temperatura máxima foi de 33,52°C e a umidade relativa do ar máxima foi de 74,63%.

A temperatura do ar média nessas instalações foi de 30,46°C, excedendo a faixa limite proposta por Baêta e Souza (2010) e Oliveira et al. (2019). Essas instalações não proporcionaram condições confortáveis aos animais. A temperatura de bulbo seco foi superior à zona termoneutra do animal, os suínos estiveram sob condições de estresse térmico todo o tempo.

A umidade relativa do ar média para essas instalações foi de 54,62%, considerada dentro dos valores desejados de 50 a 70%. No entanto, as temperaturas foram mais altas, demonstrando ser o ambiente mais estressante para os animais.

3.3.2 Análise das Variáveis fisiológicas

Os resultados das temperaturas retais (TRs) e frequência respiratória (FRs) dos animais nas baias com climatizadores e sem climatizadores, estão apresentados na Tabela 16 a seguir.

Tabela 16. Resultados das variáveis fisiológicas

Horário (horas)	Baias com climatizadores		Baias sem climatizadores	
	TR (°C)	FR (mov·min ⁻¹)	TR (°C)	FR (mov·min ⁻¹)
08:00	38,33	44,67	38,75	48,33
12:00	38,40	59,67	38,50	73,50
16:00	37,90	55,67	38,57	70,33

*TR=Temperatura retal e FR=Frequência Respiratória

De acordo com a Tabela 16, os animais das baias com climatizadores demonstraram média de temperatura retal (TR) variando de 37,90°C a 38,40°C e uma frequência respiratória (FR) média de 44,67 a 59,67 mov·min⁻¹, respectivamente. Na pesquisa de Kadirvel et al. (2022) a TR média encontrada para suínos avaliados em um ambiente de temperatura dentro da zona termoneutra (18 a 25°C) situou-se entre 36,19°C e 38,8°C. No trabalho de Ospina-Romero et al. (2023) os pesquisadores identificaram FR variando de 49,23 a 53,26 mov·min⁻¹. De acordo com Vermeulen et al. (2015), a temperatura retal quando os suínos estão na zona termoneutra é em média, 38,85 a 39,42°C. Eigenberg et al. (2005) considera que suínos estão em conforto térmico quando apresentam TR ≤ 39,3°C e FR ≤ 60 mov·min⁻¹ e acima desses limiares, estão em desconforto. Assim, os resultados indicam que os animais nessas instalações estavam, de fato, em conforto térmico.

Conforme demonstrado na Tabela 16, os animais alojados nas baias sem climatizadores apresentaram valores de temperatura retal (TR) oscilando entre 38,50°C e 38,75°C, enquanto a frequência respiratória (FR) variou de 48,33 a 73,50 mov·min⁻¹. Na pesquisa de Ospina-Romero et al. (2023) os suínos submetidos em estresse térmico apresentaram TR variando de 39,39 a 39,46°C e FR variando de 82,21 a 83,23 mov·min⁻¹. Scriba e Wechsler (2021), investigando variáveis fisiológicas de suínos em ambientes quentes, encontraram FR variando de 56,6 a 71,5 mov·min⁻¹. Wimmmler et al. (2023) identificaram valores de frequência respiratória variando de 6,2 a 107,3 mov·min⁻¹ em suínos sob estresse térmico. Melo et al. (2023) encontraram valores de FR de 88, 89 e 73 mov. min⁻¹ em suínos alojados em climas quentes. A temperatura retal dos animais permaneceu dentro da faixa indicativa de conforto, entretanto, a frequência respiratória e

as variáveis ambientais revelaram uma situação de desconforto térmico. Isso ocorreu porque em situações de estresse térmico, a frequência respiratória de suínos tende a aumentar antes que a temperatura retal atinja níveis considerados desconfortáveis, conforme observado por Rodrigues et al. (2010).

Os animais apresentaram valores de TR mais elevadas que os das baias com climatizadores e valores de FR superiores a $60 \text{ mov} \cdot \text{min}^{-1}$ respectivamente, o que superou os valores considerados ideais para essas variáveis fisiológicas e comprova que os animais estavam sob condições de estresse térmico durante o estudo para essas instalações. Isso porque a frequência respiratória dos suínos aumenta em ambientes acima da zona termoneutra de acordo com Scriba e Wechsler (2021).

As variáveis fisiológicas como a frequência respiratória e a temperatura retal, exibiram um padrão semelhante ao estudo conduzido por Campos et al. (2021) e Wimpler et al. (2023), apresentando valores inferiores pela manhã e valores máximos durante o período do meio-dia e pela tarde. Costa et al. (2023) destacam que à medida que a temperatura do ar aumenta, a frequência respiratória também aumenta.

No que diz respeito ao Índice de Temperatura de Globo Negro (ITGU), utilizado para avaliar o estresse térmico em ambientes de produção animal, este estudo adotou os critérios estabelecidos por Alves et al. (2023). Conforme esses critérios, considera-se que o ambiente está sob conforto térmico quando o ITGU está entre 68 e 74, entra na faixa de alerta entre 74 e 76, e atinge a fase de emergência quando ultrapassa 76, especificamente para suínos. Os resultados dessa análise estão apresentados na Tabela 17.

Tabela 17. ITGU das baias

ITGU	Baia com climatizadores	Baia com climatizadores
Média	71,45	79,82
Mínimo	69,12	73,63
Máximo	74,80	83,17

No ambiente com climatizador, a análise dos dados revelou que a média do ITGU foi de 71,45, com um valor mínimo de 69,12 e um valor máximo de 74,8, classificando o ambiente quanto ao nível de conforto térmico como confortável e alerta. Observou-se que o ambiente foi classificado na fase de alerta nos horários das 13:40 a 13:50h. Isso pode estar relacionada aos valores máximos de temperatura registrados nesses horários, que atingiram 24,51 e 24,87°C, exigindo ainda intervenções pontuais para garantir o conforto dos animais. Os demais horários foram mantidos em níveis ideais para o bem-estar dos suínos. Dessa forma, observou-se que os animais ficaram na fase de conforto durante 95%

do período de avaliação (das 8:00 às 16:00h), uma vez que apenas 5% do tempo (das 13:30 às 13:40h) o ambiente foi classificado na faixa de alerta. Portanto, os animais passaram a maior parte do tempo em uma condição de conforto térmico.

No ambiente sem climatizador, os valores do ITGU foram registrados em uma média de 79,82, com um valor mínimo de 73,63 e um valor máximo de 83,17. Esses resultados refletem que, em média, as condições de conforto térmico estiveram acima das condições ideais para o bem-estar dos animais. O valor mínimo foi encontrado no primeiro registro, quando a temperatura ainda estava baixa, mas com o aumento de temperatura o ITGU foi classificado como alerta e posteriormente a partir de 8:40h da manhã, o índice indicou emergência. Dessa forma, os animais foram determinados como estando sob condições de emergência na maior parte do tempo. Isso sugere que as baias sem climatizadores não foram capazes de minimizar os efeitos da temperatura local, frente às condições climatológicas da região e que essas condições ambientais não são favoráveis para o conforto térmico dos suínos, indicando que medidas são necessárias para melhorar o ambiente e garantir o bem-estar dos animais.

3.3.3 Monitoramento do comportamento dos animais

3.3.3.1 Configuração experimental

A configuração experimental foi submetida a testes em um sistema Ubuntu 22.04.3 LTS (*Long-Term Support*), que contava com um processador AMD 5 2600 de seis núcleos e 12 threads, bem como uma placa gráfica NVIDIA GeForce RTX2060 de 8 GB. No sistema local, o treinamento demandou 5 horas para 100 iterações. Devido à exigência computacional desses procedimentos, foi utilizado o *Google Colaboratory (Colab)*. No *Google Colab* os experimentos destes estudos foram conduzidos em Python-3.10.12, PyTorch-2.0.1+cu118 e CUDA:0 (Tesla T4, 15102MiB) fazendo uso da GPU gratuita disponível, onde o processamento para 100 épocas também demandou 5 horas.

Esta GPU proporcionou um aumento significativo na capacidade computacional, resultando em uma redução no tempo de treinamento e acelerando os processos de treinamento. Estudos semelhantes exploraram o emprego de GPUs para otimizar o tempo de treinamento e melhorar a velocidade do treinamento em análises com visão computacional utilizando aprendizado de máquina, como por exemplo, Ahn et al. (2021), que em sua análise comportamental de suínos, também recorreram a máquinas equipadas com GPUs. Zhuang et al. (2022) utilizaram um computador com uma GPU NVIDIA

GeForce GTX 2070 de 8 GB para realizar o reconhecimento de comportamentos relacionados à alimentação e ao consumo de água em suínos. Da mesma forma, Jiao et al. (2023) empregaram GPUs na análise das atividades suínas.

Após a aplicação da técnica de algoritmos genéticos, com um total de 15 gerações, que demandou 14,58 horas usando a NVIDIA A100-SXM4-40GB do *Colab*, os valores resultantes foram implementados no processo de treinamento do modelo YOLOv5. Os resultados obtidos destas iterações geracionais revelaram os seguintes hiperparâmetros: taxa de aprendizado inicial de 0,0082, coeficiente de momento de 0,9540 e coeficiente de decaimento de peso de 0,0005. O algoritmo foi treinado usando o otimizador Adam com um tamanho de lote de 16 imagens. Liu et al. (2023) também exploraram a aplicação do otimizador Adam em seu estudo sobre detecção de caixa delimitadora em suínos para investigar a rapidez e a precisão das detecções. Paralelamente, Yang et al. (2023) empregaram o otimizador Adam para efetuar detecções utilizando o modelo YOLOv5 em galinhas poedeiras, realizando um treinamento de 100 épocas. Todos os experimentos utilizados nesta pesquisa empregaram os mesmos hiperparâmetros mencionados acima. Foi empregado a Relu e a SofMax como função de ativação.

Na Tabela 18 estão disponibilizadas as informações sobre a duração do tempo de treinamento empregado para o reconhecimento dos comportamentos dos animais em cada um dos modelos analisados, bem como o tempo de treinamento fazendo uso de GPU e sem GPU.

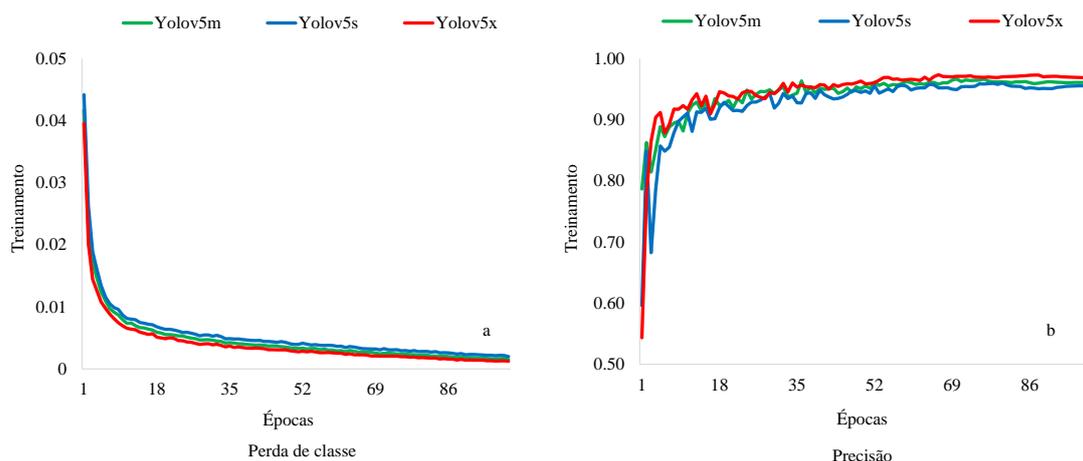
Tabela 18- Tamanho do modelo e duração do treinamento

Modelo	Tamanho do modelo (MB)	Tempo sem GPU (h)	Tempo com GPU (h)
Yolov5s	27	3,50	1,52
Yolov5m	45	5,40	1,82
Yolov5x	173	10,00	2,70

No trabalho de Sozzi et al. (2022) o YOLOv5x também foi o que demandou maior tempo de treinamento, mesmo com um número de imagens menor, porém apresentou os melhores resultados.

Os resultados obtidos durante o treinamento do YOLOv5 para as classes de comportamentos analisadas pelas diferentes versões do YOLOv5, podem ser observados analisando a evolução da função de perda para as classes (Figura 25a) e a precisão (Figura 25b) ao longo das épocas de treinamento.

Figura 25- Curva de treinamento: a) curva de perda de classe e b) precisão



O processo de treinamento do YOLOv5s começou com uma perda de classe (cls_loss) de 0,04 para as versões YOLOv5m e YOLOv5s e, de 0,03 para o YOLOv5x (Figura 25a). À medida que o treinamento avançou, na época 98, a perda foi reduzida significativamente para 0,001 para o YOLOv5s e YOLOv5m/x de 0,002 e estabilizaram-se. Resultados semelhantes foram encontrados na pesquisa conduzida por Li et al. (2023) quando a época se encontrava no intervalo de 75 a 100, a perda associada as diferentes versões do YOLOv5 diminuíram e estabilizaram-se em cerca de 0,015 a 0,03. Isso indica que, inicialmente o modelo estava aprendendo a mapear os dados de entrada para as classes corretas. Conforme o treinamento progrediu, a perda foi diminuindo à medida que o modelo ajustava seus parâmetros para se adequar aos dados. Essa redução na perda mostra que o modelo convergiu, pois, o erro começou a se estabilizar em 0,001 e não diminuiu mais após as outras iterações do treinamento sem apresentar *underfitting* ou *overfitting*.

Na Figura 25b, pode-se observar que o comportamento da precisão na curva de treinamento melhorou quando o modelo convergiu (na época 98), com precisão de 96,11 e 95,58 e para o YOLOv5m/s e o YOLOv5x obteve 97,21% na época 97 e permaneceram com esses valores até o final do treinamento. Padrões semelhantes de evolução na curva de treinamento foram identificados no estudo conduzido por Huang et al. (2023b) que notaram uma melhoria na precisão da detecção do modelo antes de atingir 100 iterações. Isso indica que todas as versões do YOLOv5 tiveram bom desempenho no treinamento e foram capazes de convergir para uma solução que minimiza a perda. Além de retratar que os modelos estão bem ajustados aos dados de treinamento e possuem capacidades de fazer

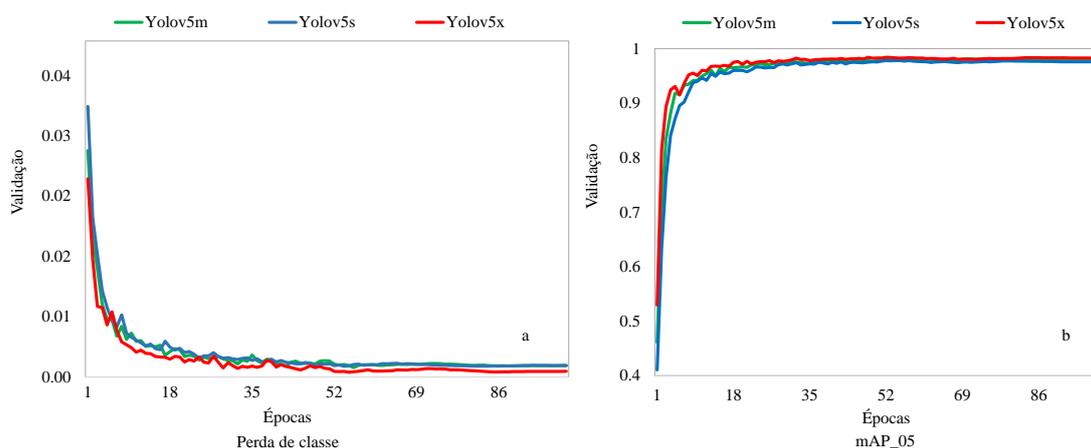
previsões mais confiáveis sobre as classes de comportamento dos animais presentes nas imagens.

Conforme visto na Figura 25b, a precisão do modelo melhora à medida que o número de iterações de treinamento aumenta. Esse comportamento da precisão também foi observado na pesquisa de Wang et al. (2023) que utilizaram o YOLOv5 para reconhecer as classes comendo, em pé e deitado em bovinos.

Os resultados obtidos demonstraram ser semelhantes aos achados de Shi et al. (2023). Assim como no estudo mencionado, quando o treinamento atingiu a convergência, a precisão média ficou estável em aproximadamente 97%, revelando consistência nos resultados obtidos. Essa semelhança nos resultados em relação ao estudo de Shi et al. (2023) indica que os modelos propostos neste trabalho possuem potencial para alcançar um desempenho promissor em detecção de objetos e visão computacional, corroborando as conclusões do estudo de referência.

A perda de validação de classe foi utilizada para avaliar a precisão na detecção dos comportamentos de suínos nas imagens. A Figura 26a ilustra a perda de classe e a Figura 26b o mAP_05 no conjunto de validação após cada época durante o processo de validação.

Figura.26- Curva de perda de classe e mAP_05 na validação



Observou-se na Figura 26a o padrão decrescente ao longo do treinamento dos modelos, indicando um progresso contínuo no desempenho à medida que os modelos aprendiam, porém, com flutuações. Essas flutuações de acordo com o estudo de Huang et al. (2023) ocorreram porque existem diferenças significativas no comportamento dos animais. O efeito do desempenho da detecção é refletido pelo aumento no mAP50% na

Figura 26b. Correspondentemente, no momento que os modelos convergiram o YOLOv5 obtiveram um mAP de 96,71 e 98,11% e se estabilizaram.

Avaliando a Figura 26, ainda se percebe que durante o processo de treinamento do modelo de detecção, à medida que o número de épocas aumentava, observou-se uma progressiva diminuição na inclinação da curva de perda de classe no conjunto de validação, culminando em uma estabilização. Conforme as épocas avançavam, foram observadas variações nos resultados das métricas de perda de localização, perda de confiança e perda de classificação. Os resultados obtidos demonstram que as métricas de precisão e recall atingiram estabilidade a partir da época 98, com valores de 97 e 96%, respectivamente. Além disso, os valores de mAP para os *thresholds* 0,5 foi de 98% conforme ilustrado. Essa estabilização das métricas indica que o modelo alcançou um desempenho consistente na detecção de objetos após esse ponto do treinamento.

3.3.3.2 Avaliação do desempenho do modelo

É comum avaliar o desempenho de modelos computacionais no conjunto de teste. Na pesquisa de Cowton et al. (2019) foi utilizado aproximadamente 800 imagens no conjunto de testes para avaliar os resultados do desempenho do YOLOv5. No presente trabalho foram utilizadas um total de 500 imagens no conjunto de teste. Os resultados obtidos no conjunto de teste estão apresentados na Tabela 19.

Tabela 19- Métricas de avaliação no conjunto de teste do yolov5m

Class	P	R	mAP50	mAP50-95
Deitado	0,982	0,980	0,992	0,948
Em pé	0,948	0,942	0,977	0,784
Média	0,965	0,961	0,984	0,866

Conforme apresentado na Tabela 19, os resultados demonstram que o modelo YOLOV5m alcançou uma precisão de 0,982, indicando que foi capaz de identificar corretamente 98,2% das instâncias dessa classe e um recall de 98,0%. Além disso, a métrica mAP50 que representa a média de precisão com um limiar de confiança de 50%, atingiu 99,2%, enquanto a mAP50-95, que avalia a média de precisão em uma faixa mais ampla de confiança (50 a 95%), obteve um valor de 94,8%. Para o comportamento em pé, o modelo registrou uma precisão de 94,8% e recall de 94,2%. As métricas mAP50 e mAP50-95 atingiram 97,7 e 78,4%, respectivamente e os valores médios foram a precisão de 0,965, recall de 0,961, mAP50 de 0,984 e mAP50-95 de 0,866.

Resultados semelhantes foram identificados no estudo de Li et al. (2023), que também conduziram experimentos com o YOLOv5m para a detecção de cabeças de suínos, alcançando uma precisão de 96,10%, um recall de 86,70%, e valores de mAP05 de 93,50% e mAP95 de 94,20%, demonstrando o potencial do algoritmo em aplicações na produção animal.

Na pesquisa conduzida por Guo et al. (2023) os pesquisadores encontraram uma precisão de 99,3 e 99,1%, com recall de 98,1% para a detecção de galinhas poedeiras em granjas comerciais utilizando o YOLOv5. No estudo de Zhou (2022a) os autores encontraram uma precisão de 0,989, um recall de 0,996, mAP0.50 de 0,994 e mAP0.50 :0.95 de 0,796 para detectar suínos usando o YOLOv5m.

Os resultados destacam a eficácia do modelo ao analisar e identificar padrões em um conjunto representativo. Essas métricas servem como indicadores fundamentais para avaliar o desempenho geral do YOLOv5. Na Tabela 20, são exibidas a precisão, o recall, mAP50 e mAP50-95 do modelo YOLOv5s para o conjunto de teste.

Tabela 20- Métricas de avaliação no conjunto de teste do yolov5s

Class	P	R	mAP50	mAP50-95
Deitado	0,984	0,981	0,985	0,975
Em pé	0,962	0,941	0,985	0,952
Média	0,973	0,961	0,985	0,963

Para o comportamento deitado, o modelo demonstrou uma precisão de 0,984 (98,4%), indicando a exatidão das detecções relacionadas a esse comportamento e registrou um recall de 0,981 (98,1%), o que significa que identificou 98,1% dos casos deste comportamento. A métrica mAP50, atingiu 0,985 (98,5%), enquanto a mAP50-95 obteve um valor de 0,975 (97,5%). No caso do comportamento em pé, o modelo apresentou uma precisão de 0,962 (96,2%), com recall de 0,941 (94,1%). Já as métricas mAP50 e mAP50-95 alcançaram 0,985 (98,5%) e 0,952 (95,2%), respectivamente. Os valores médios para os comportamentos dos animais foram precisão de 0,973, recall de 0,961, mAP50 e mAP50-95 de 0,985 e 0,963. Isso mostra que ao aumentar o limite de confiança, o mAP50-95% a precisão média diminuiu.

Em um estudo realizado por Huang et al. (2023b) para detectar suínos, os autores alcançaram um mAP50 de 95,2% e um mAP50-95 de 65,83%. O mAP50 relatado de 95,2% indica um alto nível de precisão na detecção de objetos relacionados a suínos usando o modelo *yolov5*, com um limite de confiança de 50%. No entanto, a diminuição do mAP50-95 para 65,83% sugere que à medida que o limite de confiança é estendido

para uma faixa mais ampla (50 a 95%), o desempenho do modelo em termos de precisão média diminui, indicando que dentro de uma faixa de confiança mais ampla de 50 a 95%, os valores de mAP para YOLOv5s foram mais baixos. Este comportamento do mAP50-95 é condizente com os resultados obtidos no presente estudo, fornecendo suporte adicional para a eficácia do modelo YOLOv5 em estudos com suínos.

Na Tabela 21, foram apresentadas as métricas de avaliação YOLOv5x, obtidas a partir da análise do conjunto de dados de teste para as diferentes classes de comportamento animal.

Tabela 21. Métricas de avaliação no conjunto de teste do yolov5x

Class	P	R	mAP50	mAP50-95
Deitado	0,987	0,984	0,993	0,960
Em pé	0,962	0,941	0,969	0,744
Média	0,974	0,962	0,981	0,852

Para a classe deitado, observou-se uma precisão (P) de 0,987, indicando que o modelo foi capaz de identificar corretamente 98,7% das instâncias relacionadas a essa classe. O recall associado a essa classe foi de 0,984 (98,4%), o que denota uma taxa de recuperação satisfatória. As métricas mAP50 e mAP50-95 foram calculadas em 0,993 (99,3) e 0,969 (96,9%), respectivamente, reforçando o desempenho satisfatório do modelo para essa classe. A classe em pé revelou uma precisão de 0,962, ressaltando que o modelo acertou 96,2% das vezes em que os animais estavam desenvolvendo atividades em pé. O recall, calculado em 0,941 (94,1%), sugere uma boa capacidade de recuperação de exemplos positivos. As métricas mAP50 e mAP50-95, com valores de 0,969 (96,9%) e 0,744 (74,4%), indicam a capacidade consistente do modelo em identificar os comportamentos do animal em pé. Os valores médios para o modelo foram a precisão de 0,974, recall de 0,962, mAP50 e mAP50-95 de 0,981 e 0,852. Na pesquisa de Sivamani et al. (2020) a precisão foi de 0,99 para detectar o comportamento de suínos em pé, para suínos deitados a precisão foi de 0,98 e o mAP de 0,95. Na pesquisa de Zhou (2022b) para realizar a detecção e contagem de suínos a precisão do yolov5x foi de 0,989, recall de 0,996, mAP0.50 de 0,994 e mAP0.50 :0.95 de 0,796. Na pesquisa de Mao et al. (2024), o método YOLOv5 demonstrou elevada precisão no reconhecimento dos comportamentos em pé, deitado ventral e deitado lateralmente, com valores no conjunto de validação atingindo 99,1; 95,3 e 97,4%, respectivamente.

No geral, conforme os níveis de confiança foram elevados, as previsões passaram por um processo gradual de filtragem, resultando em métricas $mAP_{05:95}$ reduzidas. Isso indica que ao aumentar o nível de confiança necessário para considerar uma detecção como válida, o modelo tornou-se mais conservador em suas previsões, resultando em menor número de detecções aceitas, mas com maior confiança na sua precisão. Esse resultado também foi observado por Ahn et al. (2021). Esse procedimento, é útil para controlar o número de detecções falsas positivas e melhorar a qualidade geral das previsões em cenários de alta exigência em termos de confiabilidade. No entanto, é importante observar que, ao impor um limite mais rigoroso, o modelo também pode perder algumas detecções verdadeiras, o que pode explicar a redução nas métricas, precisão e o recall.

Esse resultado destaca limitações do algoritmo em situações em que são exigidos limites mais precisos para a definição de detecções corretas e, portanto, esses resultados sinalizam a necessidade de direcionar esforços para aprimorar e ajustar o modelo, buscando melhorar sua capacidade de detecção em cenários mais complexos e com maior sobreposição de objetos. Resultados semelhantes foram encontrados no trabalho de Wang et al. (2023), que também encontraram um desempenho inferior para a métrica $mAP_{0.95}$, especialmente na faixa de limite de IoU entre 0,5 e 0,95.

As características e especificações técnicas do modelo utilizado na pesquisa também foram analisadas, e os resultados revelam que o modelo *yolov5m* demanda um poder computacional de 47.9 GFLOPs. Enquanto isso, o modelo *yolov5s* requer um poder computacional de 15.8 GFLOPs e o modelo *yolov5x* exige um poder computacional maior, alcançando 203.9 GFLOPs. Resultados semelhantes foram obtidos por Meng et al. (2023) e Liu et al. (2023), que também obtiveram um valor de 15,8 GFLOPs em seus experimentos usando *yolov5s*. Por outro lado, o estudo de Wu et al. (2023) revelou um valor ligeiramente maior de 16,5 GFLOPs. É importante ressaltar que Wang et al. (2023) conseguiram reduzir significativamente o poder de computação necessário, de 15,8 para 4,7 GFLOPs, ao utilizar o MobileNetV3-Large como substituto para a rede de backbone CSPDarknet53 do YOLOv5s em seus respectivos trabalhos. Esses achados apontam para possíveis otimizações que podem ser aplicadas no modelo para melhorar sua eficiência computacional sem comprometer o desempenho de detecção.

Além disso, também foi observado o tempo médio necessário para executar a inferência do modelo em cada imagem, ou seja, o tempo para que o modelo processe os dados de entrada e gere as previsões de detecção de objetos. Para o YOLOv5m foi de 1,5

ms, para o YOLOv5s/x foi de 2,8 ms, permitindo que o modelo analise 7,70 imagens por segundo.

Para a aplicação do YOLOv5 na pecuária inteligente, especialmente para tarefas como a avaliação do comportamento dos animais e da saúde, deve-se considerar os requisitos específicos relacionados ao tamanho da rede, velocidade de detecção e eficiência computacional, devido à natureza dinâmica e em tempo real das operações realizadas, como sugere Liu et al. (2023) para implantação do YOLOv5 em sistemas de automação e robôs inteligentes.

Os resultados provenientes da análise de variância (ANOVA) apontam que não há evidências substanciais que indiquem uma diferença significativa no desempenho médio entre os modelos YOLOv5s, YOLOv5m e YOLOv5x para as classes comportamentais, ao nível de significância de 5% para a precisão (p-valor = 0,567), revocação (p-valor = 0,714), medida-F (p-valor = 0,675) e acurácia (p-valor = 0,682).

No entanto, ao comparar e considerar os requisitos de produção da indústria suína, foi selecionado o YOLOv5s com o maior mAP50-95 e o menor número de parâmetros, por tornar o modelo mais leve.

Após o treinamento, o modelo detecta cada animal individualmente quando recebe uma imagem. Cada resultado de detecção é marcado com uma caixa delimitadora, que possui um rótulo e um número indicando sua probabilidade de pertencer a esse rótulo, conforme Figura 27.

Figura.27- Resultado das detecções do YOLOv5.

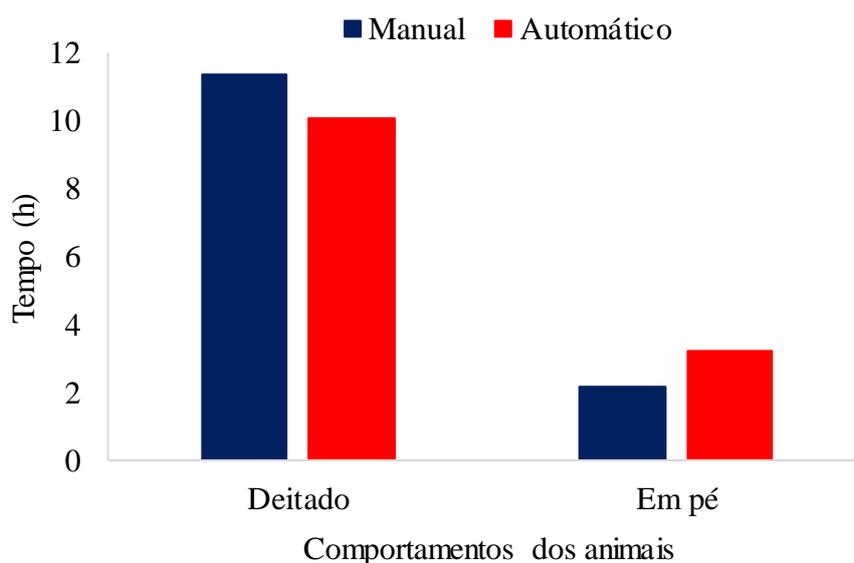


A observação da Figura 27 revelou que as probabilidades atribuídas pelo modelo para pertencer às classes deitado ou em pé variaram de 0,9 a 1, indicando que o modelo tem capacidade de diferenciar entre essas categorias de comportamento.

3.3.3.3 Identificação de padrões de comportamento nos suínos

A Figura 28 mostra os resultados do monitoramento manual e o monitoramento automático dos suínos submetidos nas baias com climatização, durante o período experimental para os comportamentos de deitar-se e ficar em pé.

Figura.28- Monitoramento manual e estimado nas baias com climatização

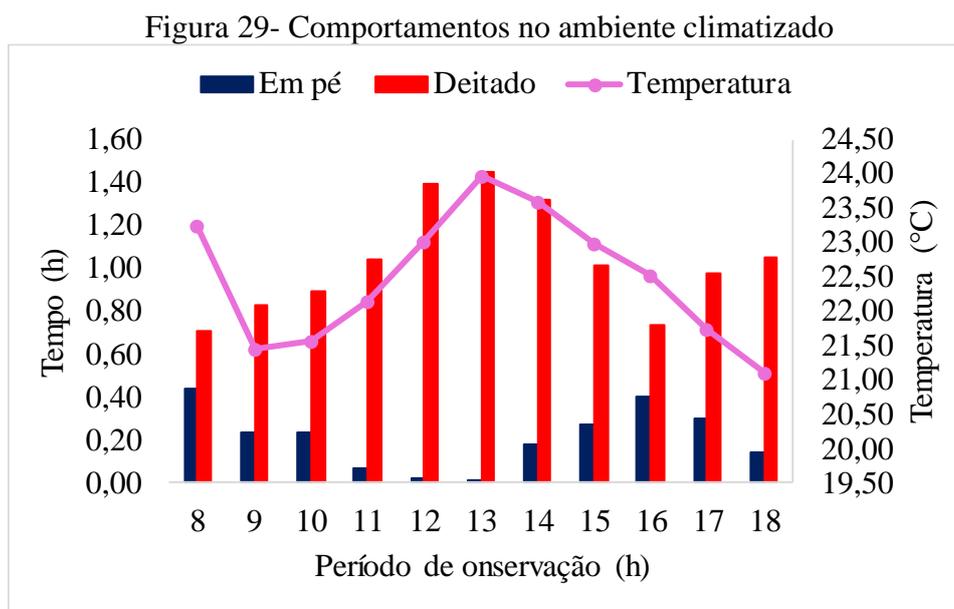


A maior diferença encontrada entre o monitoramento manual e o automático foi para a classe em pé, incluindo as atividades de investigação e locomoção, já que os suínos ficam em pé enquanto investigam ou se locomovem. A diferença máxima encontrada foi de 0,933h. O monitoramento manual revelou que os animais ficaram em pé 2.282h, enquanto o automático mostrou 3.215h (20,03%). Na classe deitado o monitoramento manual mostrou que os animais ficaram deitados 11.384h, enquanto o modelo revelou 10.913h (68,02%), uma diferença de 0,47 h.

Essas diferenças observadas entre as medições manual e automática podem ser atribuídas as imagens do conjunto de dados. Em alguns vídeos, a iluminação comprometeu a capacidade do modelo em discernir entre o piso da baia e os animais que estavam deitados ou dormindo sobre ele, especialmente devido à semelhança nas colorações, devido ao piso da baia ter sido praticamente da cor dos animais. O piso sujo com excretas dos animais também contribuiu, uma vez que o modelo, ao detectar áreas

suas, interpretou erroneamente essas regiões como animais, influenciando assim as estimativas de comportamento. Além disso, nas instalações estava instalado um segundo comedouro sem uso, cuja coloração se assemelhava à dos animais, resultou em detecções incorretas, levando o modelo a identificar o comedouro como sendo animais. Na pesquisa de Luo et al. (2021) que empregaram o YOLOv5 para detectar a postura de suínos, o modelo perdeu detecções e realizou detecções errôneas devidos problemas de iluminação que escondia os animais.

Na Figura 29, estão apresentados os comportamentos deitados e em pé nas baias com climatizadores associados aos valores de temperatura do local.



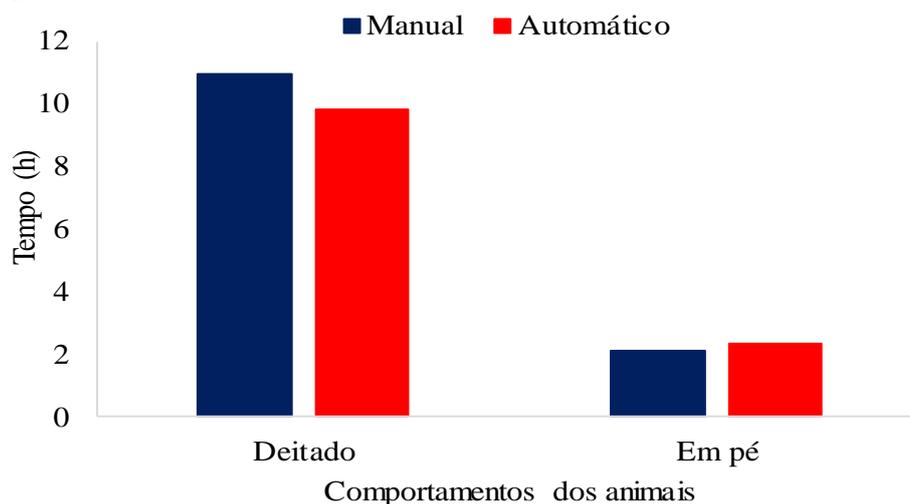
Os resultados da Figura 29 demonstram que os animais do ambiente climatizado passaram a maior parte do tempo, cerca de 11,38h (68,02%), deitados, principalmente no horário de maior temperatura (12 e 13h). Além disso, 2,28h, (20,03%) do tempo os animais desenvolveram atividades de ficar em pé, como investigação e locomoção. Este comportamento sugere que os suínos preferem permanecer deitados na maior parte do tempo em um ambiente climatizado, o que pode indicar um maior nível de conforto e bem-estar nesse tipo de ambiente. No trabalho de Luo et al. (2021) os suínos dormiram cerca de 70% do tempo analisado, com uma maior proporção de suínos deitados das 12 h às 13h.

No trabalho de Robbins et al. (2021) os suínos passaram a maior parte do tempo deitados (50%) quando submetidos a temperaturas dentro da zona termoneutra (18 a 21°C). Isso mostra que as condições ambientais impactam significativamente o

comportamento. Araújo et al. (2022) destacaram que os suínos são altamente sensíveis às mudanças na temperatura ambiente e apresentam melhor desempenho quando mantidos em ambiente térmico confortável. Ferrari e Camargo (2023) observaram que os animais exploraram mais o ambiente quando a temperatura do ar estava na zona termoneutra.

A Figura 30 representa os resultados do monitoramento do comportamento dos animais nas baias sem climatização. Essas observações são provenientes das avaliações tanto manuais quanto automáticas.

Figura 30. Monitoramento manual e automático nas baias não climatizadas



Os resultados da Figura 30 revelam que os animais no ambiente natural passaram a maior parte do tempo deitados, com uma avaliação manual registrando 10,96h e uma avaliação do modelo mostrando 9,84h (69,71%), resultando em uma diferença de 1,12h. Além disso, os animais realizaram atividades em pé, como investigação e locomoção, por 2,14h, enquanto a avaliação do modelo indicou 2,36h (16,78%), resultando em uma diferença de 0,22h. Ferrari e Camargo (2023) observaram que os animais exploraram mais o ambiente quando a temperatura do ar estava na zona termoneutra. No presente estudo, as baias não climatizadas estavam em desconforto térmico com valores de temperaturas superiores a zona termoneutra (18 a 26°C), por isso essa atividade foi menos observada entre os animais alojados nas baias sem climatização.

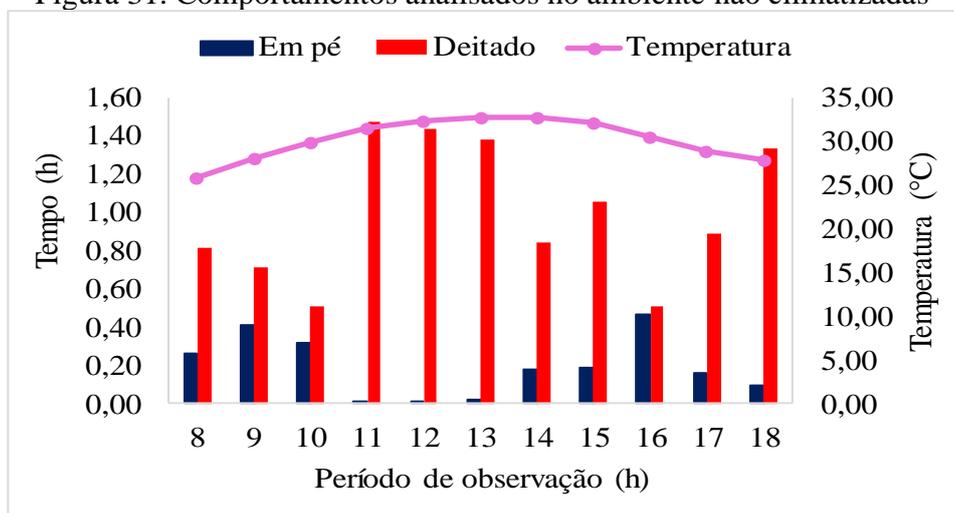
Em relação a diferença na classe deitada entre o observado e o estimado, essa disparidade é atribuída à limitação do modelo em diferenciar os animais deitados no chão, semelhantes às baias climatizadas, devido à semelhança na coloração. Em situações em que os animais se sobrepujam, as detecções eram perdidas, refletindo uma limitação na capacidade do modelo. Essa limitação também foi identificada por Guo et al. (2023) em

seu trabalho de detecção de galinhas, onde o YOLOv5 perdeu detecções devido à sobreposição e aglomeração dos animais. Na pesquisa de Luo et al. (2021) quando parte do corpo do porco estava faltando ou bloqueada por obstáculos como iluminação, o YOLOv5 perdeu a detecção dos suínos. No estudo de Ding et al. (2022) os autores encontraram desafios relacionados à iluminação, o YOLOv5 perdeu detecções de leitões e obteve detecções falsas em cenários de interferência, com luz intensa.

Quanto à classe em pé, o desempenho das detecções pode ter sido afetado pela presença do comedouro sem uso na baia e pelo piso molhado devido aos excretos dos animais, o que resultou em uma tonalidade mais escura no piso (semelhantes aos animais das baias climatizadas). Esses elementos podem ter contribuído para detecções falsas, como observado no trabalho de Zhou (2022b) que usaram o YOLOv5 para detectar e contar suínos e o modelo também confundiu o comedouro com um animal, isto porque o modelo tende a enfatizar a cor do alvo e não a forma. No estudo conduzido por Luo et al. (2021) foram identificados desafios na detecção de posturas deitadas em suínos. Este problema emergiu devido à proximidade da cabeça do porco em relação ao chão, resultando na ocultação das patas dianteiras, que ficam essencialmente escondidas à frente do peito. Essas condições de iluminação desfavoráveis, dificultou ainda mais a capacidade do modelo em identificar de forma precisa os animais quando se encontravam na posição deitada. Na pesquisa de Guo et al. (2023) também foram identificadas detecções falsas pelo YOLOv5 na presença de equipamentos nas instalações das aves.

A Figura 31, apresenta a representação visual dos comportamentos deitados e em pé observados nas baias sem climatizadores, em associação com a temperatura do ar permitindo uma visão das respostas comportamentais frente as temperaturas.

Figura 31. Comportamentos analisados no ambiente não climatizadas



O monitoramento automático revela que os animais passaram a maior parte do tempo de observação em repouso. A atividade deitada foi a que totalizou o maior tempo, cerca de 9,84 h (69,71%) do tempo analisado, sendo que o horário que os animais permaneceram mais tempo deitados foi de 11 a 13 h e no final do dia, às 18h. Esse padrão comportamental é frequentemente observado em suínos que são expostos a ambientes quentes como estratégias para perder calor com o piso. Dado que os suínos não possuem a capacidade de suar, eles adotam estratégias específicas para lidar com temperaturas elevadas, como repousar sobre superfícies mais frias como uma forma de regular a temperatura corporal (WIMMLER et al., 2023). Além disso, a pesquisa conduzida por Pang & Chen (2023) revelou que esses animais passaram a maior parte de seu tempo em repouso, destacando que em seu estudo com porcas lactantes, os suínos passaram cerca de 44,30% do dia em sono. Na pesquisa de Ahn et al. (2021) os pesquisadores destacaram que os suínos são propensos a períodos prolongados de sono, corroborando essa observação.

O comportamento em pé demandou 2,36 h (16,78%) e foi incluído nessa categoria os comportamentos de andar e investigar. Esse comportamento está de acordo com o estudo realizado por Ocepek et al. (2020) que identificou que, nas fases de crescimento e terminação de suínos, o comportamento exploratório foi o segundo mais frequente, sendo superado apenas pelo comportamento de deitado/dormindo. Sendo esses comportamentos úteis para medir a saúde e o bem-estar dos animais de produção de acordo com Odo et al. (2023).

3.3.4 Comportamento de comer e beber

O comportamento de ingestão de alimentos e de água foi analisado nos segmentos de vídeos após a alimentação dos suínos, realizada duas vezes ao dia (manhã e tarde). O consumo de água foi analisado tendo em vista os animais comerem e em seguida irem ao bebedouro. As métricas precisão e *recall* foram utilizadas para calcular erros de previsão e avaliar o desempenho da proposta mostrados na Tabela 22.

Tabela 22- Métricas de desempenho

Métricas	Bebendo	Comendo	Média
P	0,97	0,98	0,975
Recall	0,96	0,98	0,970

Como pode ser visto, para os resultados de previsão baseados em intervalos de tempo de 30 min, o modelo obteve para a classe bebendo a precisão e recall de 0,97 e 0,96, respectivamente, com valores médios de 0,975 e 0,970. Na classe comendo o modelo obteve precisão e recall de 0,98. Isso indica forte concordância entre os valores observados e os previstos. Os resultados desses estudos apresentam semelhanças com os obtidos por Chen et al. (2020) os quais demonstraram um desempenho no reconhecimento do comportamento alimentar de suínos no conjunto de testes, alcançando uma precisão de 0,984, recall de 0,988 e uma precisão média de 0,959.

Na pesquisa conduzida por Tu et al. (2024) foi observada precisão de 0,944 no reconhecimento do comportamento de alimentação em suínos alojados em baias comerciais, utilizando o modelo YOLOv5.

Jiang et al. (2020) utilizaram o YOLOv5 para a detecção de comportamentos de comer e beber em cabras e alcançaram precisões médias de 0,978 e 0,982, respectivamente. Alameer et al. (2020) utilizaram o YOLOv5 para verificar o comportamento alimentar de suínos e alcançaram a precisão de reconhecimento de 0,994. Tsai et al. (2020) usaram uma rede de aprendizagem profunda para o reconhecimento dos comportamentos de beber e alimentar de vacas e alcançaram precisão média de 0,978.

A Tabela 23 apresenta dados do tempo utilizado pelos animais na ingestão de água e no consumo de ração pelos animais nas baias climatizadas e nas baias sem climatizadores.

Tabela 23- Ingestão de água dos animais nos ambientes estudados

Atividades	Climatizado		Não climatizado	
	Manual	Automático	Manual	Automático
Bebendo	0,0678h	0,0635h	0,1031h	0,1636h
Comendo	1,7909h	1,8518h	1,6674h	1,7419h

Para o comportamento de beber, o método manual registrou média de 0,067 h no ambiente climatizado, enquanto o método automático indicou 0,063h (0,39%). No ambiente natural, a observação manual registrou 0,103h, enquanto o método automático registrou 0,1636h (1,15%). Para o comportamento de comer, o método manual registrou uma média de 1,790 h no ambiente climatizado, enquanto o método automático registrou 1,8518h (11,54%). No ambiente natural, a observação manual registrou 1,6674h, enquanto o método automático registrou 1,7419h (12,33%). Isso pode ter ocorrido, devido à falta de descontinuidade dos frames, uma vez que o animal não está mais bebendo, porém, a sua caixa delimitadora ocupa toda a região do bebedouro.

Os resultados indicam que o YOLOv5 é capaz de identificar o comportamento dos animais, embora aconteça ligeiras variações nas medições entre os métodos. A menor diferença (0,0043) ocorreu para a classe bebendo no ambiente climatizado, onde a observação manual detectou 0,0678h e o modelo detectou 0,0635h. A maior diferença ocorreu para a classe comendo (0,0745) no ambiente natural. Essa diferença pode estar associada a presença de uma lona que foi colocada para evitar interferência do ambiente climatizado e pode ter confundido o modelo e ter causado dificuldades no algoritmo detectando mais animais no comedouro (Figura 32).

Figura 32. Ilustração da lona nas baias não climatizadas



Nos vídeos com melhor luminosidade nas instalações dos animais, os suínos tornam-se mais destacados, sendo assim, foram melhor identificados pelo modelo e portanto, pode discriminá-los com mais precisão. A alta precisão da discriminação de luminosidade facilita o monitoramento dos animais no período diurno.

Ainda observando a Tabela 23, verifica-se que os animais do ambiente climatizado demandaram em torno de 0,0678h bebendo água, enquanto os animais do ambiente natural beberam em torno de 0,1031h. Os resultados obtidos indicam que os animais do ambiente climatizado beberam menos água, com uma redução de aproximadamente 34,56% em comparação com os do ambiente natural (0,0678h no ambiente climatizado em comparação com 0,103h no ambiente natural). Essa diminuição pode ser interpretada como uma resposta adaptativa ao ambiente mais frio, sugerindo que a necessidade de hidratação pode ser menor nessas condições. Isso porque os animais das baias sem climatizadores estavam sob temperatura superior a zona termoneutra e de acordo com Oliveira et al. (2023) os animais quando são submetidos a uma temperatura

superior à sua zona de conforto térmico, aumenta a ingestão de água e diminui o consumo de alimento (OLIVEIRA et al., 2023).

Os animais alojados nessas baias apresentaram um consumo de água inferior (0,11h) (0,68%) em comparação com os animais nas baias sem climatizadores. Oliveira et al. (2017) também identificaram essa tendência, observando que em ambientes com temperatura superior a 26°C, os suínos demonstraram um aumento no consumo de água. Esses achados corroboram os resultados identificados por Ferrari e Camargo (2023) que também verificaram que os suínos em ambientes quentes ingerem mais água. Esse padrão comportamental alinha-se com as observações deste estudo, onde os animais no ambiente climatizado demonstraram maior propensão a permanecer em pé e realizar mais visitas ao bebedouro.

No que diz respeito à atividade de comer, os animais no ambiente climatizado apresentaram uma média de 7,42% a mais de tempo dedicado a essa atividade em comparação com os do ambiente natural (1,7909h no ambiente climatizado em comparação com 1,6674h no ambiente natural). Essa diferença sugere uma possível resposta aos diferentes ambientes, indicando que fatores climáticos podem influenciar os padrões alimentares dos animais.

Esses achados corroboram o estudo de Rao et al. (2023) que também investigaram o comportamento de suínos tanto em ambientes climatizados quanto em ambientes não climatizados e observaram o mesmo padrão comportamental. Na pesquisa de Pan et al. (2023) as porcas lactantes comeram por 1,06% do tempo analisado. Hörtenhuber et al. (2020) afirmam que essa observação está associada ao microclima do ambiente, uma vez que suínos expostos a temperaturas elevadas apresentam uma redução no consumo de ração.

Tais resultados foram semelhantes aos encontrados por Silva et al. (2023) que analisaram o comportamento dos suínos em ambiente climatizado e identificaram que os animais consumiram mais ração nessa condição. Cross et al. (2018) descrevem que em condições ambientais de temperatura elevada, suínos tendem a reduzir sua ingestão de alimentos e diminuir suas visitas ao comedouro. Um padrão comportamental semelhante foi observado por Zhang et al. (2022) que observaram que os animais sob temperatura adequada comem mais e bebem menos água. Esses comportamentos quando comparados com os dados das variáveis fisiológicas mostram-se correlacionados, uma vez que os animais das baias climatizadas apresentaram os menores valores das variáveis fisiológicas.

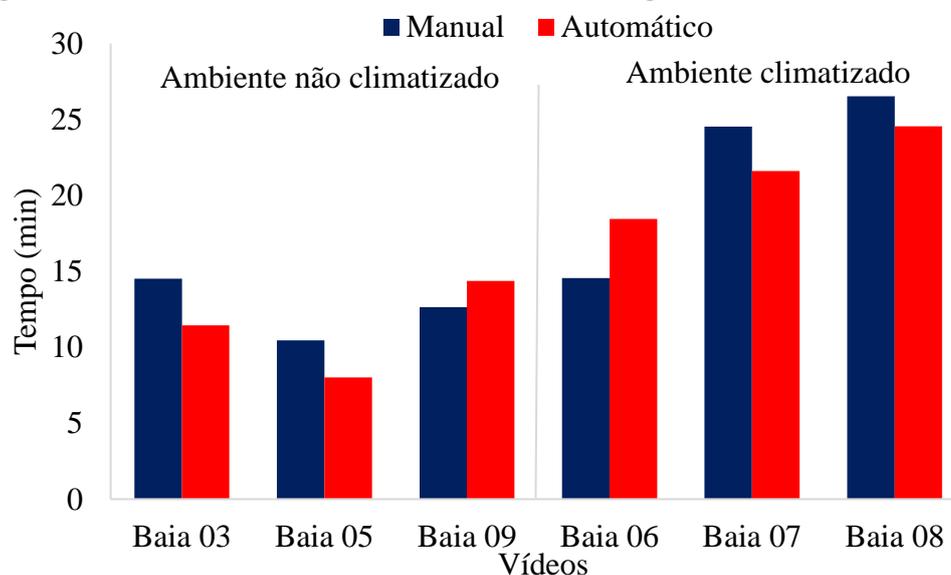
Oliveira et al. (2023) observaram que o consumo de alimentos em baias cujas temperaturas se encontravam dentro da faixa de conforto térmico para suínos nas fases de crescimento e terminação foi superior em comparação com baias submetidas a temperaturas mais elevadas. Dessa forma, foi observado que o ambiente climatizado contribuiu para a redução do estresse térmico e, conseqüentemente, para o aumento no consumo de ração.

Por outro lado, a atividade beber foi a que demandou o menor tempo 0,0635 h, sendo a menos observada em comparação com as outras atividades. O ato de beber para suínos é de curta duração e sua ocorrência segundo Arablouei et al. (2023b) é ocasional. Essa observação também está condizente com os achados de Pan et al. (2023), aos quais também monitorou comportamentos de porcas lactantes e observaram que os animais apresentaram curtos períodos de ingestão de água (1,63%).

Os animais das baias climatizadas, comeram mais, beberam menos água, ficaram mais tempo em pé e dormiram mais que os animais das baias sem climatizadores. Esses comportamentos, quando comparados com os dados das variáveis fisiológicas mostraram-se correlacionados, uma vez que os animais das baias climatizadas apresentaram os menores valores das variáveis fisiológicas.

Para verificar a generalização do algoritmo no reconhecimento do comportamento de comer e beber dos suínos, os vídeos de 30 minutos foram divididos em segmentos de 5 min de cada uma das instalações experimentais, conforme mostrado na Figura 33.

Figura 33- Monitoramento visual e automático da ingestão de alimentos nas baias



Foram selecionados para fins de verificação vídeos de cada uma das baias após o fornecimento de ração para evitar a possibilidade de o animal investigar o comedouro sem ter comida. Os resultados na Figura 33 mostram que o método proposto detecta efetivamente as atividades de comer dos animais em cada quadro do vídeo. A proposta pode realizar o monitoramento dos suínos para verificar a ocorrência do comportamento de alimentação de forma contínua, isso indica que o modelo pode ser utilizado para monitoração em ambientes de criação convencionais e apresenta boa generalização.

Os resultados mostram, que a maioria dos animais das baias sem climatizadores passaram menos tempo no comedouro. Ao associar estes comportamentos com as variáveis ambientais, observa-se que essas baias apresentaram maior temperatura e menor umidade. Os dados do monitoramento utilizando o sistema proposto automatizado demonstraram claramente que o comportamento de beber reflete os efeitos do estresse térmico nos suínos. De acordo com Kiefer et al. (2010), animais submetidos a temperaturas mais elevadas, reduzem o consumo de ração. A temperatura termo neutra na fase de terminação é de 18°C, e a temperatura que causa estresse térmico é superior a 27°C. As médias de temperaturas, nessas baias foram superiores a 27°C.

O monitoramento de suínos, é uma parte importante da criação inteligente de animais. O monitoramento de forma automática pode ajudar os agricultores a melhorar a produção e evitar o desperdício de tempo. No entanto, sistema de iluminação, equipamentos instalados e a cor do piso das instalações podem representar muitos desafios para a detecção de suínos.

3.4. Conclusões

Os comportamentos de deitar e ficar em pé são indicadores do bem-estar e da saúde dos suínos em ambientes coletivos. O modelo YOLOv5, treinado para identificar esses comportamentos, demonstrou alta eficiência, alcançando uma taxa de precisão média de 97,3% e uma revocação média de 96,1%. Além de detectar com precisão os suínos em pé e deitados, os resultados mostraram que o modelo foi capaz de identificar diferenças comportamentais associadas às condições climáticas dos alojamentos. Especificamente, os suínos alojados em baias sem climatizadores passaram menos tempo em pé, enquanto aqueles em baias climatizadas ficaram mais tempo em pé. Esses achados indicam que o modelo YOLOv5 é uma ferramenta confiável para monitorar suínos em tempo real, promovendo práticas de criação mais adequadas, saudáveis e eficientes.

O algoritmo exibiu taxas de precisão média de 97,5% e recordação média de 97,0% no reconhecimento do comportamento alimentar e do consumo de água dos suínos. Os resultados mostraram que o modelo foi capaz de identificar os comportamentos dos animais associados ao clima, uma vez que os animais das baias sem climatizadores passaram menos tempo no comedouro, enquanto os animais das baias climatizadas passaram mais tempo. A proposta pode ser utilizada em vídeos de vigilância ou imagens e minimiza a necessidade de intervenção manual, oferecendo um meio eficiente de monitorizar o comportamento dos suínos em ambientes agrícolas e de contribuir para a produtividade das operações de criação de suínos, garantindo condições mais adequadas e saudáveis para os suínos, além de promover práticas de criação mais sustentáveis e eficientes.

Referências

- ADORNO, P. L. V.; JASENOVSKI, I. M.; SANTIAGO, D. F. D. M.; BERGAMASCO, L. Automatic detection of people with reduced mobility using YOLOv5 and data reduction strategy. Proceedings of the XIX Brazilian Symposium on Information Systems. **Anais...** . p.9–16, 2023. New York, NY, USA: ACM.
- AHN, H.; SON, S.; KIM, H.; et al. EnsemblePigDet: Ensemble Deep Learning for Accurate Pig Detection. **Applied Sciences** **2021**, Vol. **11**, Page **5577**, v. 11, n. 12, p. 5577, 2021. Multidisciplinary Digital Publishing Institute. Disponível em: <<https://www.mdpi.com/2076-3417/11/12/5577/htm>>. Acesso em: 18/12/2023.
- ALAMEER, A.; KYRIAZAKIS, I.; BACARDIT, J. Automated recognition of postures and drinking behaviour for the detection of compromised health in pigs. **Scientific Reports**, v. 10, n. 1, p. 13665, 2020.
- ALVES, M. DE F. A.; PANDORFI, H.; MONTENEGRO, A. A. DE A.; et al. Evaluation of Body Surface Temperature in Pigs Using Geostatistics. **AgriEngineering**, v. 5, n. 2, p. 1090–1103, 2023. Disponível em: <<https://web.p.ebscohost.com/abstract?direct=true&profile=ehost&scope=site&authtype=crawler&jrnl=26247402&AN=164575621&h=do4JpOVMDep3fgb7eZINUhSi%2F8A1P6GzbAQ2ldU9oUdfX3gF0uvQGOyEiYmeiX9EWDxxTY68QhBJklJi5hd42g%3D%3D&crl=c&resultNs=AdminWebAuth&resultLocal=>>>. Acesso em: 8/12/2023.
- ARABLOUEI, R.; WANG, L.; CURRIE, L.; et al. Animal behavior classification via deep learning on embedded systems. **Computers and Electronics in Agriculture**, v. 207, p. 107707, 2023a.
- ARABLOUEI, R.; WANG, L.; CURRIE, L.; et al. Animal behavior classification via deep learning on embedded systems. **Computers and Electronics in Agriculture**, v. 207, p. 107707, 2023b. Elsevier. Acesso em: 30/9/2023.
- ARAÚJO, R. G. R.; GUIMARÃES, T. P.; GOMES, M. R. Influência dos fatores climáticos sobre o desempenho, qualidade de carcaça e carne de suínos: revisão bibliográfica. **Research, Society and Development**, v. 11, n. 3, p. e10711326327, 2022.

- BAÊTA, F. C.; SOUZA, C. F. **Ambiência em edificações rurais: conforto animal**. Viçosa, 2010.
- BARBOSA FILHO, J. A. D.; SILVA, I. J. O.; SILVA, M. A. N.; SILVA, C. J. M. Avaliação dos comportamentos de aves poedeiras utilizando sequência de imagens. **Engenharia Agrícola**, v. 27, n. 1, p. 93–99, 2007.
- BEZERRA, A. C.; BEZERRA DA SILVA, J. L.; DE OLIVEIRA SILVA, D. A.; et al. Monitoramento Espaço-Temporal da Detecção de Mudanças em Vegetação de Caatinga por Sensoriamento Remoto no Semiárido Brasileiro. **Revista Brasileira de Geografia Física**, v. 13, n. 1, p. 286–301, 2020.
- BUFFINGTON, D. E.; COLLAZO-AROCHO, A. ; CANTON, G. H.; PITT, D. Black Globe-Humidity Index (BGHI) as comfort equation for dairy cows. **Transactions of the ASA**, v. 24, p. 711–714, 1981.
- CAMPOS, J. C. D.; PASSINI, R.; NASCIMENTO, K. F. M. DO. Thermography and physiology of stress in dairy calves in outdoor holding pens covered with geosynthetics. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 25, n. 11, p. 787–793, 2021.
- CAMPOS, J. C. D.; PASSINI, R.; SOUSA, L. J. M. P. E; AMARAL, A. DAS G. Alterações comportamentais de bezerras criadas em bezerreiros tropicais com cobertura alternativa. **Ciência Animal Brasileira**, v. 24, 2023.
- CHANG, Y.-H.; ZHANG, Y.-Y. Deep Learning for Clothing Style Recognition Using YOLOv5. **Micromachines**, v. 13, n. 10, p. 1678, 2022.
- CHEN, C.; ZHU, W.; STEIBEL, J.; et al. Recognition of feeding behaviour of pigs and determination of feeding time of each pig by a video-based deep learning method. **Computers and Electronics in Agriculture**, v. 176, p. 105642, 2020.
- COSTA, A.; ISMAYILOVA, G.; BORGONOVO, F.; et al. The use of image analysis as a new approach to assess behaviour classification in a pig barn. **Acta Veterinaria Brno**, v. 82, n. 1, p. 25–30, 2013.
- COSTA, D. A. DA; SANTOS, V. M. DOS; OLIVEIRA, A. V. D. DE; et al. Efeito da sazonalidade sobre as respostas fisiológicas e produtivas de vacas leiteiras mestiças ao clima amazônico equatorial. **Ciência Animal Brasileira**, v. 24, 2023.
- COWTON, J.; KYRIAZAKIS, I.; BACARDIT, J. Automated Individual Pig Localisation, Tracking and Behaviour Metric Extraction Using Deep Learning. **IEEE Access**, v. 7, p. 108049–108060, 2019.
- CROSS, A. J.; KEEL, B. N.; BROWN-BRANDL, T. M.; CASSADY, J. P.; ROHRER, G. A. Genome-wide association of changes in swine feeding behaviour due to heat stress. **Genetics Selection Evolution**, v. 50, n. 1, p. 11, 2018.
- DING, Q.; LIU, L.; LU, M.; et al. Social density detection for suckling piglets based on convolutional neural network combined with local outlier factor algorithm. **Computers and Electronics in Agriculture**, v. 202, p. 107423, 2022.
- EIGENBERG, R. A.; BROWN-BRANDL, T. M.; NIENABER, J. A.; HAHN, G. L. Dynamic Response Indicators of Heat Stress in Shaded and Non-shaded Feedlot Cattle, Part 2: Predictive Relationships. **Biosystems Engineering**, v. 91, n. 1, p. 111–118, 2005.

- ESCOBAR-AMADO, C.; BADIEY, M.; WAN, L. Computer Vision for Bioacoustics: Detection of Bearded Seal Vocalizations in the Chukchi Shelf Using YOLOV5. **IEEE Journal of Oceanic Engineering**, p. 1–12, 2023.
- FAN, J.; CUI, L.; FEI, S. Waste Detection System Based on Data Augmentation and YOLO_EC. **Sensors**, v. 23, n. 7, p. 3646, 2023.
- FERRAZ JARDIM, A. M. DA R.; DE QUEIROZ, M. G.; ARAÚJO JÚNIOR, G. D. N.; DA SILVA, M. J.; FREIRE DA SILVA, T. G. ESTUDOS CLIMÁTICOS DO NÚMERO DE DIAS DE PRECIPITAÇÃO PLUVIAL PARA O MUNICÍPIO DE SERRA TALHADA-PE. **REVISTA ENGENHARIA NA AGRICULTURA - REVENG**, v. 27, n. 4, p. 330–337, 2019.
- GONZAGA, L. M.; ALMEIDA, G. M.; SANTOS, C. M. C. V. Identificação e medição de defeitos em produtos automotivos utilizando visão computacional. **Peer Review**, v. 5, n. 7, p. 1–20, 2023.
- GUO, Y.; AGGREY, S. E.; YANG, X.; et al. Detecting broiler chickens on litter floor with the YOLOv5-CBAM deep learning model. **Artificial Intelligence in Agriculture**, v. 9, p. 36–45, 2023.
- HAN, S.; FUENTES, A.; YOON, S.; et al. Deep learning-based multi-cattle tracking in crowded livestock farming using video. **Computers and Electronics in Agriculture**, v. 212, p. 108044, 2023.
- HAO, WANGLI; ZHANG, K.; ZHANG, L.; et al. TSML: A New Pig Behavior Recognition Method Based on Two-Stream Mutual Learning Network. **Sensors**, v. 23, n. 11, p. 5092, 2023.
- HAO, W.; HAN, W.; HAN, M.; LI, F. A Novel Improved YOLOv3-SC Model for Individual Pig Detection. **Sensors**, v. 22, n. 22, p. 8792, 2022.
- HUANG, Y.; XIAO, D.; LIU, J.; et al. An Improved Pig Counting Algorithm Based on YOLOv5 and DeepSORT Model. **Sensors**, v. 23, n. 14, p. 6309, 2023a.
- HUANG, Y.; XIAO, D.; LIU, J.; et al. An Improved Pig Counting Algorithm Based on YOLOv5 and DeepSORT Model. **Sensors**, v. 23, n. 14, p. 6309, 2023b.
- JIANG, M.; RAO, Y.; ZHANG, J.; SHEN, Y. Automatic behavior recognition of group-housed goats using deep learning. **Computers and Electronics in Agriculture**, v. 177, p. 105706, 2020.
- JIAO, T.; LI, F.; CUI, Y.; et al. Deep Learning With an Attention Mechanism for Differentiating the Origin of Brain Metastasis Using <scp>MR</scp> images. **Journal of Magnetic Resonance Imaging**, v. 58, n. 5, p. 1624–1635, 2023.
- JOCHER, G.; STOKEN A; J. BOROVEC; S.T.A. Ultralytics/yolov5: V4. 0-Nn. Silu () activations weights & biases logging pytorch hub integration. , 2021. Disponível em: <<https://zenodo.org/record/4418161>>. Acesso em: 10/1/2024.
- KADIRVEL, G.; GONMEI, C.; SINGH, N. S. Assessment of Rectal Temperature using Infrared Thermal Camera in Pigs. **Indian Journal Of Science And Technology**, v. 15, n. 40, p. 2041–2046, 2022.
- KHAN, N.; ZAIDI, S. F. A.; YANG, J.; PARK, C.; LEE, D. Construction Work-Stage-Based Rule Compliance Monitoring Framework Using Computer Vision (CV) Technology. **Buildings**, v. 13, n. 8, p. 2093, 2023.

- KIEFER, C., MEIGNEN, B. C. G., SANCHES, J. F., & CARRIJO, A. S. Resposta de suínos em crescimento mantidos em diferentes temperaturas. **Archivos de zootecnia**, v. 58, n. 221, p. 55–64, 2009.
- KIEFER, C.; MOURA, M. S. DE; SILVA, E. A. DA; et al. Respostas de suínos em terminação mantidos em diferentes ambientes térmicos. **Revista brasileira de Saúde Produção Animal**, v. 11, n. 2, p. 496–504, 2010.
- KIM, T.; KIM, Y.; KIM, S.; KO, J. Estimation of Number of Pigs Taking in Feed Using Posture Filtration. **Sensors**, v. 23, n. 1, p. 238, 2022.
- LAI, J.; LIANG, Y.; KUANG, Y.; et al. IO-YOLOv5: Improved Pig Detection under Various Illuminations and Heavy Occlusion. **Agriculture**, v. 13, n. 7, p. 1349, 2023.
- LI, J.; PAN, H.; LI, JUNFENG. ESD-YOLOv5: A Full-Surface Defect Detection Network for Bearing Collars. **Electronics**, v. 12, n. 16, p. 3446, 2023.
- LIU, G.; HU, Y.; CHEN, Z.; GUO, J.; NI, P. Lightweight object detection algorithm for robots with improved YOLOv5. **Engineering Applications of Artificial Intelligence**, v. 123, p. 106217, 2023.
- LIU, H.; DUAN, X.; LOU, H.; et al. Improved GBS-YOLOv5 algorithm based on YOLOv5 applied to UAV intelligent traffic. **Scientific Reports**, v. 13, n. 1, p. 9577, 2023.
- LIU, Y.; WANG, F.; LIU, K.; et al. Deep convolutional autoencoder thermography for artwork defect detection. **Quantitative InfraRed Thermography Journal**, 2023. Taylor & Francis. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/17686733.2023.2225246>>. Acesso em: 8/12/2023.
- LI, Y.; LI, J.; NA, T.; YANG, H. Detection of attack behaviour of pig based on deep learning. **Systems Science and Control Engineering**, v. 11, n. 1, 2023. Taylor and Francis Ltd. Acesso em: 14/10/2023.
- LUO, Y.; ZENG, Z.; LU, H.; LV, E. Posture Detection of Individual Pigs Based on Lightweight Convolution Neural Networks and Efficient Channel-Wise Attention. **Sensors**, v. 21, n. 24, p. 8369, 2021.
- MA, C.; TAO, J.; TAN, C.; LIU, W.; LI, X. Negative Media Sentiment about the Pig Epidemic and Pork Price Fluctuations: A Study on Spatial Spillover Effect and Mechanism. **Agriculture**, v. 13, n. 3, p. 658, 2023.
- MAO, L.; LIU, C.; LI, Y.; ZHU, W.; WANG, L. An improved YOLOv5 for identifying pigs postures. In: T. Limongi; H. Lin (Orgs.); Second International Conference on Electrical, Electronics, and Information Engineering (EEIE 2023). **Anais...** p.106, 2024. SPIE.
- MASSARI, J. M.; CURI, T. M. R. DE C.; MOURA, D. J.; MEDEIROS, B. B. L.; SALGADO, D. D. Características comportamentais de suínos em crescimento e terminação em sistema “wean to finish”. **Engenharia Agrícola**, v. 35, n. 4, p. 646–656, 2015.
- MELO, K. K. DE S. V.; MACHADO, N. A. F.; BARBOSA FILHO, J. A. D.; et al. Pre-slaughter management in Northeast Brazil and the effects on thermophysiological indicators in pigs and pH45. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 27, n. 4, p. 287–292, 2023.
- MENG, X.; LIU, Y.; FAN, L.; FAN, J. YOLOv5s-Fog: An Improved Model Based on YOLOv5s for Object Detection in Foggy Weather Scenarios. **Sensors**, v. 23, n. 11, p. 5321, 2023.

- MOREIRA, V. E.; VERONEZE, R.; TEIXEIRA, A. DOS R.; et al. Effects of Ambient Temperature on the Performance and Thermoregulatory Responses of Commercial and Crossbred (Brazilian Piau Purebred Sires × Commercial Dams) Growing-Finishing Pigs. **Animals**, v. 11, n. 11, p. 3303, 2021.
- NEPAL, U.; ESLAMIAT, H. Comparing YOLOv3, YOLOv4 and YOLOv5 for Autonomous Landing Spot Detection in Faulty UAVs. **Sensors**, v. 22, n. 2, p. 464, 2022.
- NIE, L.; LI, B.; DU, Y.; et al. Deep learning strategies with CReToNeXt-YOLOv5 for advanced pig face emotion detection. **Scientific Reports**, v. 14, n. 1, p. 1679, 2024.
- OCEPEK, M.; GOOLD, C. M.; BUSANČIĆ, M.; AARNINK, A. J. A. Maize silage as enrichment material improves the welfare of growing-finishing pigs in environmentally-friendly pens. **Applied Animal Behaviour Science**, v. 230, p. 105043, 2020.
- ODO, A.; MUNS, R.; BOYLE, L.; KYRIAZAKIS, I. Video Analysis Using Deep Learning for Automated Quantification of Ear Biting in Pigs. **IEEE Access**, v. 11, p. 59744–59757, 2023.
- OLIVEIRA, A. C. DA F. DE; VANELLI, K.; SOTOMAIOR, C. S.; WEBER, S. H.; COSTA, L. B. Impacts on performance of growing-finishing pigs under heat stress conditions: a meta-analysis. **Veterinary Research Communications**, v. 43, n. 1, p. 37–43, 2019.
- DE OLIVEIRA, M. J. K.; VALK, M.; MELO, A. D. B.; et al. Feeding Behavior of Finishing Pigs under Diurnal Cyclic Heat Stress. **Animals**, v. 13, n. 5, p. 908, 2023.
- OSPINA-ROMERO, M. A.; MEDRANO-VÁZQUEZ, L. S.; PINELLI-SAAVEDRA, A.; et al. Productive Performance, Physiological Variables, and Carcass Quality of Finishing Pigs Supplemented with Ferulic Acid and Grape Pomace Subjected to Heat Stress Conditions. **Preprints**, p. 050–933, 2023.
- PANDORFI, H.; SILVA, I. J. O. Evaluation of the behavior of piglets in different heating systems using analysis of image and electronic identification. **Agricultural Engineering International**, v. 7, n. 8, p. 1–24, 2005.
- PANG, F.; CHEN, X. MS-YOLOv5: a lightweight algorithm for strawberry ripeness detection based on deep learning. **Systems Science & Control Engineering**, v. 11, n. 1, 2023.
- PAN, Z.; CHEN, H.; ZHONG, W.; WANG, A.; ZHENG, C. A CNN-Based Animal Behavior Recognition Algorithm for Wearable Devices. **IEEE Sensors Journal**, v. 23, n. 5, p. 5156–5164, 2023.
- ROBBINS, L. A.; GREEN-MILLER, A. R.; JOHNSON, J. S.; GASKILL, B. N. One Is the Coldest Number: How Group Size and Body Weight Affect Thermal Preference in Weaned Pigs (3 to 15 kg). **Animals**, v. 11, n. 5, p. 1447, 2021.
- RODRIGUES, N. E. B.; ZANGERONIMO, M. G.; FIALHO, E. T. Adaptações fisiológicas de suínos sob estresse térmico. **Revista Eletrônica Nutritime**, v. 7, n. 2, p. 1197–1211, 2010.
- SANTOS, M. F. O. DE M.; QUARTO, C. C. Classificação de libras em imagens através de redes neurais convolucionais. **Brazilian Journal of Development**, v. 8, n. 12, p. 80897–80915, 2022.
- SCRIBA, M. F.; WECHSLER, B. Behavioural and physiological indicators of heat stress in fattening pigs. **Agrarforschung Schweiz**, v. 12, p. 181–188, 2021.
- SHAO, H.; PU, J.; MU, J. Pig-Posture Recognition Based on Computer Vision: Dataset and Exploration. **Animals**, v. 11, n. 5, p. 1295, 2021.

- SHI, J.; GONG, H.; CONG, L.; REN, M.; LIANG, H. Detecting temperature segregation in asphalt pavement construction using infrared imaging and deep learning. **International Journal of Pavement Engineering**, v. 24, n. 1, 2023.
- SHI, L.; SUN, J.; DANG, Y.; et al. YOLOv5s-T: A Lightweight Small Object Detection Method for Wheat Spikelet Counting. **Agriculture**, v. 13, n. 4, p. 872, 2023.
- SILVA, W. A. DA; PANDORFI, H.; VIGODERIS, R. B.; et al. Exploratory inference of the ingestive behavior of pigs in the growth phase in an air-conditioned environment. **Livestock Science**, v. 272, p. 105232, 2023.
- SIVAMANI, S.; BASKAR, R.; CHANDRASEKARAN, A. P. Response surface optimization of acid pretreatment of cassava stem for bioethanol production. **Environmental Progress & Sustainable Energy**, v. 39, n. 2, 2020.
- SOZZI, M.; CANTALAMESSA, S.; COGATO, A.; KAYAD, A.; MARINELLO, F. Automatic Bunch Detection in White Grape Varieties Using YOLOv3, YOLOv4, and YOLOv5 Deep Learning Algorithms. **Agronomy**, v. 12, n. 2, p. 319, 2022.
- SULZBACH, J. J.; MENDES, A. S.; POSSENTI, M. A.; DE SOUZA, C.; NUNES, I. B. Evaluation of different heating systems for new-born swine. **International Journal of Biometeorology**, v. 64, n. 9, p. 1473–1479, 2020.
- TITTO, C. G.; RICCI, G. DELA. Behavioral and physiological changes in sows and piglets maintained in farrowing cages or open stalls during summer. **Journal of Veterinary Behavior**, v. 63, p. 36–41, 2023.
- TRINDADE, G. N.; MOTA, A. V.; TOLEDO, T. S.; CARDINAL, K. M. EFEITO DA TEMPERATURA NA PRODUÇÃO DE SUÍNOS EM DIFERENTES FASES. **Zootecnia: tópicos atuais em pesquisa**. p.97–109, 2023. Editora Científica Digital.
- TSAI, Y.-C.; HSU, J.-T.; DING, S.-T.; RUSTIA, D. J. A.; LIN, T.-T. Assessment of dairy cow heat stress by monitoring drinking behaviour using an embedded imaging system. **Biosystems Engineering**, v. 199, p. 97–108, 2020.
- TU; SHUQIN AND CAI; YIFAN AND LIANG; et al. Tracking and Monitoring of Individual Pig Behavior Based on Yolov5-Byte. **SSRN**, 2024.
- VERMEULEN, L.; VAN DE PERRE, V.; PERMENTIER, L.; DE BIE, S.; GEERS, R. Pre-slaughter rectal temperature as an indicator of pork meat quality. **Meat Science**, v. 105, p. 53–56, 2015.
- WANG, C.; ZHANG, Y.; ZHOU, Y.; et al. Automatic detection of indoor occupancy based on improved YOLOv5 model. **Neural Computing and Applications**, v. 35, n. 3, p. 2575–2599, 2023. Springer London. Disponível em: <<https://doi.org/10.1007/s00521-022-07730-3>>. .
- WANG, R.; GAO, R.; LI, Q.; DONG, J. Pig Face Recognition Based on Metric Learning by Combining a Residual Network and Attention Mechanism. **Agriculture**, v. 13, n. 1, p. 144, 2023.
- WANG, Z.; PANG, Y.; ULUS, C.; ZHU, X. Counting manatee aggregations using deep neural networks and Anisotropic Gaussian Kernel. **Scientific Reports**, v. 13, n. 1, p. 19793, 2023.
- WIMMLER, C.; LEEB, C.; WINCKLER, C.; KNOLL, M.; HOLINGER, M. The long and short of showers: Effects of shower duration on behaviour, thermal comfort and soiling of organic growing-finishing pigs with access to outdoor runs. **Applied Animal Behaviour Science**, v. 258, p. 105826, 2023.

- WITTE, J.-H.; MARX GÓMEZ, J. Introducing a new Workflow for Pig Posture Classification based on a combination of YOLO and EfficientNet., 2022.
- YANG, B.; ZHANG, L.; HE, J. Research on rice disease recognition based on improved SPPFCSPC-G YOLOv5 network. **PLOS ONE**, v. 18, n. 12, p. e0295661, 2023.
- YANG, Q.; XIAO, D.; LIN, S. Feeding behavior recognition for group-housed pigs with the Faster R-CNN. **Computers and Electronics in Agriculture**, v. 155, p. 453–460, 2018.
- YIN, M.; MA, R.; LUO, H.; et al. Non-contact sensing technology enables precision livestock farming in smart farms. **Computers and Electronics in Agriculture**, v. 212, p. 108171, 2023.
- ZHANG, G.; YIN, J.; DENG, P.; et al. Achieving Adaptive Visual Multi-Object Tracking with Unscented Kalman Filter. **Sensors**, v. 22, n. 23, p. 1–18, 2022.
- ZHANG, M.; DUNSHEA, F. R.; WARNER, R. D.; et al. Impacts of heat stress on meat quality and strategies for amelioration: a review. **International Journal of Biometeorology**, v. 64, n. 9, p. 1613–1628, 2020.
- ZHOU, Z. Detection and Counting Method of Pigs Based on YOLOV5_Plus: A Combination of YOLOV5 and Attention Mechanism. **Mathematical Problems in Engineering**, v. 2022, p. 1–16, 2022a.
- ZHOU, Z. Detection and Counting Method of Pigs Based on YOLOV5_Plus: A Combination of YOLOV5 and Attention Mechanism. **Mathematical Problems in Engineering**, v. 2022, p. 1–16, 2022b.
- ZHUANG, Y.; ZHOU, K.; ZHOU, Z.; JI, H.; TENG, G. Systems to Monitor the Individual Feeding and Drinking Behaviors of Growing Pigs Based on Machine Vision. **Agriculture**, v. 13, n. 1, p. 103, 2022.