

UNIVERSIDADE DE SÃO PAULO
FACULDADE DE ZOOTECNIA E ENGENHARIA DE ALIMENTOS

JONATHAN VINICIUS DOS SANTOS

Avaliação do comportamento de suínos em ambientes com diferentes sistemas de resfriamentos utilizando modelos computacionais

PIRASSUNUNGA

2022

JONATHAN VINICIUS DOS SANTOS

Avaliação do comportamento de suínos em ambientes com diferentes sistemas de resfriamentos utilizando modelos computacionais

Versão corrigida

Tese de Doutorado apresentada à Faculdade de Zootecnia e Engenharia de Alimentos da Universidade de São Paulo, como parte dos requisitos para a obtenção do Título de Doutor em Ciências.

Área de Concentração: Qualidade e Produtividade Animal

Orientadora: Profa Dra Luciane Silva Martello

Co-orientador: Prof Dr Rafael Vieira de Sousa

PIRASSUNUNGA

2022

Ficha catalográfica elaborada pelo
Serviço de Biblioteca e Informação, FZEA/USP,
com os dados fornecidos pelo(a) autor(a)

S237a Santos, Jonathan Vinicius
Avaliação do comportamento de suínos em ambientes com diferentes sistemas de resfriamentos utilizando modelos computacionais / Jonathan Vinicius Santos ; orientador Luciane Silva Martello ; coorientador Rafael Vieira de Sousa. -- Pirassununga, 2022.
77 f.

Tese (Doutorado - Programa de Pós-Graduação em Zootecnia) -- Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo.

1. Aprendizado Profundo. 2. Bem-estar Animal. 3. Comportamento Animal. 4. Análise de Imagem. 5. Zootecnia de Precisão. I. Silva Martello, Luciane, orient. II. Vieira de Sousa, Rafael, coorient. III. Título.

DEDICATÓRIA

A Deus, por estar presente em minha vida e em todos os momentos.

Aos meus pais, irmão e ao Emerson, pelo incentivo, apoio e amo incondicional.

Amo vocês!

AGRADECIMENTOS

À Deus, que é a força maior que rege toda a natureza.

Aos meus pais Jussara e Nilson, que confiaram em mim e torceram para que eu alcançasse meus sonhos e objetivos. Agradeço por tudo que fizeram e que fazem por mim até hoje e assim chegar onde estou. Obrigado por todo apoio, amor e força necessária para eu continuar meu caminho. Amo vocês!

**À minha irmã Ávila por todo o carinho e amor de sempre e para sempre. Te amo
vida!**

**Ao meu querido e melhor companheiro Emerson, que acompanhou toda essa trajetória ao meu lado, que me inspirou, me deu forças, puxou minhas orelhas, me fez confiar que eu era capaz, para que hoje esse dia chegasse com muito orgulho.
Te amo muito!**

À minha orientadora Profa Dra Luciane Silva Martello, por me aceitar como seu orientado, por me incentivar, apoiar e confiar no meu potencial durante esses três anos. Muito obrigado.

Ao meu Coorientador Prof Dr Rafael Vieira de Sousa, por acreditar em mim, me apoiar e incentivar nos estudos da pesquisa. Muito obrigado!

Ao Prof Dr Holmer pela parceria e disponibilidade dos dados no qual sem os mesmo, não seria possível a realização deste trabalho. Obrigado!

Ao meu melhor amigo Marcos, por sempre estar junto acompanhando minha carreira desde a época do técnico e por sempre me aconselhar, me incentivar e ajudar nas minhas escolhas. Obrigado irmão!

À minha amiga Shara, por sempre acreditar em mim, no meu potencial e sempre me dar forças em suas orações para que eu pudesse continuar minha caminhada. Te amo!

À minha amiga Kátia, por dar bons conselhos, por estar ao lado, incentivando e me cobrindo com carinho e atenção. Muito obrigado!

Ao meu amigo Emanuel, por me ajudar e incentivar no doutorado. Pelos nossos momentos de diversão e parceria. Muito obrigado!

Ao técnico do laboratório Edson, que sempre me ajudou, apoiou e se dedicou para que a pesquisa desse certo. Muito obrigado!

À minha amiga Débora, por toda a ajuda, companheirismo e dedicação ao meu experimento, para que tudo ocorresse bem. Muito obrigado!

À prefeitura do Campus Fernando Costa, por disponibilizar os laboratórios para a realização deste projeto.

À todos os funcionários do Departamento de Engenharia de Biossistemas.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

MUITO OBRIGADO!!!

RESUMO

SANTOS, J.V. **Avaliação do comportamento de suínos em ambientes com diferentes sistemas de resfriamentos utilizando modelos computacionais.** 2019. 79 f. Qualificação (Doutorado) – Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga, 2019.

A observação contínua do comportamento de animais para avaliação do bem-estar em criadouros é laboriosa e, por isso, diversos trabalhos de pesquisa têm buscado propor sistemas automáticos de visão computacional para execução de tal tarefa. A análise de imagens digitais utilizando Redes Neurais Convolucionais (RNC) é um método promissor que tem sido aplicado em diversas áreas para reconhecimento de padrões de comportamento. O objetivo do estudo é avaliar por meio de ferramenta computacional de vídeo-imagem, dados ambientais e parâmetros fisiológicos, o padrão comportamental de suínos em ambientes com diferentes tipos de sistemas de resfriamento, sendo tratamento A (Aspersão), AV (Aspersão mais Ventilação), V (Ventilação) e NV (Nebulização mais Ventilação). Foram utilizadas vídeo-imagens de um banco de dados, que foi adquirido em uma instalação denominada Câmara de Preferência Ambiental, na qual 8 suínos foram monitorados durante 10 horas por dia, perfazendo um total 420 horas de vídeos gravados por 42 dias. Os comportamentos avaliados serão: suíno andando, suíno bebendo, suíno comendo, e suíno deitado, além do conjunto ambiente vazio. Estes vídeos foram processados por um algoritmo em linguagem de programação Python 3.5.4 rcl. Outro algoritmo em MATLAB foi utilizado para selecionar e classificar quadros (sub-imagens) de 200x200 e 100x100 da imagem de acordo com o conteúdo visualizado (comportamento), gerando o banco de dados de quadros que foi usado para a construção do modelo computacional baseado em RNC com protocolo baseado em validação cruzada de 60% dos quadros para a construção do modelo, 20% para validação e 20% para o teste, selecionados de forma aleatória. A biblioteca Keras para Python foi utilizada para implementar a arquitetura de camadas da RNC. Os resultados foram analisados de acordo com a frequência de cada um dos comportamentos. Dois modelos foram construídos com dois bancos de dados distintos, sendo um desbalanceado com 48.486 imagens e outro balanceado de maneira manual com 29.352 imagens, obtendo uma acurácia de 99% e 99,4% respectivamente. Em seguida, foi desenvolvida a ferramenta FC (Frequency Counter), que fez a contabilização do tempo e quantas vezes o animal realizou determinado comportamento. De acordo com a FC, os animais beberam e comeram mais no tratamento A (2,5% e 13,5%) e apresentaram maiores valores de temperatura da nuca e frequência respiratória (35,6 °C e 54,6 mov/min) respectivamente. Por fim, conclui-se que o melhor modelo obtido foi o com a base de dados balanceados, onde obteve-se uma acurácia de 99,4%; A partir da FC, foi possível observar um padrão comportamental dos animais, sendo o tratamento A os animais passaram mais tempo bebendo e comendo, e no tratamento V mais tempo deitados e os tratamentos de modo geral, apresentaram efeito sobre as respostas fisiológicas.

Palavras-chave: Aprendizado profundo. Avaliação de comportamento. Processamento de imagens. Zootecnia de precisão.

ABSTRACT

SANTOS, J. V. **Evaluation of swine behavior in environments with different cooling systems using computer models.** 2019. 79 f. Qualification (Doctorate) - Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, 2019.

The continuous observation of the behavior of animals to evaluate the welfare in breeding places is laborious and, therefore, several research works have sought to propose automatic computer vision systems to perform this task. The analysis of digital images using Convolutional Neural Networks (CNN) is a promising method that has been applied in several areas for behavior pattern recognition. The objective of the study is to evaluate, by means of a video-image computational tool, environmental data and physiological parameters, the behavioral pattern of pigs in environments with different types of cooling systems, being treatment A (Sprinkler), AV (Sprinkler plus Ventilation), V (Ventilation) and NV (Nebulization plus Ventilation). Video images from a database were used, which were acquired in an installation called Câmara de Prevenção Ambiental, in which 8 pigs were monitored for 10 hours a day, making a total of 420 hours of videos recorded for 42 days. The behaviors evaluated will be: swine walking, swine drinking, swine eating, and swine sleeping, in addition to the empty environment set. These videos were processed by an algorithm in Python 3.5.4 rcl programming language. Another algorithm in MATLAB was used to select and classify frames (sub-images) of 200x200 and 100x100 of the image according to the visualized content (behavior), generating the database of frames that was used to build the computational model based on RNC with protocol based on cross-validation of 60% of the frames for the construction of the model, 20% for validation and 20% for the test, selected at random. The Keras library for Python was used to implement the RNC layered architecture. The results were analyzed according to the frequency of each of the behaviors. Two models were built with two different databases, one unbalanced with 48,486 images and the other balanced with 29,352 images, obtaining an accuracy of 99% and 99.4% respectively. Then, the FC (Frequency Counter) tool was developed, which counted the time and how many times the animal performed a certain behavior. According to HR, the animals drank and ate more in treatment A (2.5% and 13.5%) and had higher values of neck temperature and respiratory rate (35.6 °C and 54.6 mov/min) respectively. Finally, it is concluded that the best model obtained was the one with the balanced database, where an accuracy of 99.4% was obtained; From the FC, it was possible to observe a behavioral pattern of the animals, with treatment A the animals spent more time drinking and eating, and in treatment V more time lying down and the treatments in general had an effect on the physiological responses.

Keywords: Deep learning. Behavior assessment. Image processing. Precision animal husbandry.

LISTA DE FIGURAS

Figura 1 – Vista da CPA	33
Figura 2 - Desenho ilustrativo da vista superior da CPA	34
Figura 3 - Vista do compartimento experimental com destaque para os sensores loggers	36
Figura 4 - Imagem ilustrativa do programa com a seleção da área a ser analisada	37
Figura 5 - Recorte do suíno no tamanho de 200x200	39
Figura 6 - Recorte do suíno no tamanho de 100x100	39
Figura 7 - Configuração de cores, nomes e comportamentos dos animais para o <i>labeling</i>	43
Figura 8 - Seleção do animal para inserir um novo <i>label</i>	44
Figura 9 - Seleção do comportamento para inserir um novo <i>label</i>	44
Figura 10 - Novo <i>label</i> inserido no ponto indicado	45
Figura 11 - <i>Frame</i> com todos os comportamentos anotados	45
Figura 12 - Dados do <i>labeling</i> , armazenados em arquivo-texto com campos separados por tabulações	46
Figura 13 - Relatório final gerado pela ferramenta FC	47
Figura 14 - Médias das imagens de termografia de infravermelho (°C) da região da nuca e das frequências respiratórias (movimentos/minuto) dos animais em relação aos tratamentos Aspersão (A), Apersão e Ventilação (AV), Ventilação (V) e Nebulização e Ventilação (NV)	56
Figura 15 - Médias da frequência (%) do comportamento Manejo para os tratamentos Ventilação (V), Aspersão (A), Aspersão e Ventilação (AV) e Nebulização e Ventilação (NV)	61
Figura 16 - Médias da frequência (%) do comportamento Andando para os tratamentos Ventilação (V), Aspersão (A), Aspersão e Ventilação (AV) e Nebulização e Ventilação (NV)	62
Figura 17 - Médias da frequência (%) do comportamento Bebendo para os tratamentos Ventilação (V), Aspersão (A), Aspersão e Ventilação (AV) e Nebulização e Ventilação (NV)	63
Figura 18 - Médias da frequência (%) do comportamento Comendo para os tratamentos Ventilação (V), Aspersão (A), Aspersão e Ventilação (AV) e Nebulização e Ventilação (NV)	64

Figura 19 - Médias da frequência (%) do comportamento Deitado para os tratamentos Ventilação (V), Aspersão (A), Aspersão e Ventilação (AV) e Nebulização e Ventilação (NV)66

LISTA DE TABELA

Tabela 1 - Zona de termoneutralidade das matrizes, leitões e suínos até a terminação.....	22
Tabela 2 - Comparação de banco de dados desbalanceados e balanceados	30
Tabela 3 - Etograma de trabalho para avaliação comportamental (classes).....	37
Tabela 4 - Total de imagens desbalanceadas em cada classe de comportamento utilizada para cada etapa do treinamento, da validação e de teste do processamento da rede neural convolucional	39
Tabela 5 - Total de imagens após o balanceamento, em cada classe e para cada etapa do treinamento, da validação e de teste do processamento da rede neural convolucional.....	40
Tabela 6 - Etograma comportamental para o desenvolvimento da ferramenta FC.....	41
Tabela 7 - Matriz confusão resultante do teste do modelo criado com banco de dados desbalanceado.....	48
Tabela 8 - Matriz confusão resultante do teste do modelo criado com banco de dados balanceado.....	50
Tabela 9 - Dados de temperatura do ar e umidade relativa do ar para os tratamentos Apersão (A), Nebulização e Ventilação (NV) Apersão e Ventialção (AV) e Ventilação (V). Os dados estão demonstrados em média \pm erro padrão.....	52
Tabela 10 - Análise descritiva dos dados de comportamento diário para os tratamentos Apersão (A), Apersão e Ventilação (AV), Nebulização e Ventilação (NV) e Ventilação (V).....	56

SUMÁRIO

1	INTRODUÇÃO E JUSTIFICATIVA.....	12
2	HIPÓTESES.....	14
3	OBJETIVO	15
3.1	Objetivos específicos.....	15
4	REVISÃO BIBLIOGRÁFICA.....	16
4.1	Importância do comportamento e bem-estar animal.....	16
4.3	Ferramenta computacional para avaliação do comportamento	27
4.3.1	Inteligência Artificial	28
4.3.2	Redes Neurais Convolucionais.....	29
5	MATERIAL E MÉTODOS.....	32
5.1	Período experimental.....	32
5.1.1	Instalação e Sistemas de Resfriamento.....	32
5.1.2	Coleta de dados.....	36
5.2	Construção do modelo baseado em RNC.....	37
5.2.1	Construção da <i>Frequency Counter</i> (FC) e Avaliação do comportamento animal	42
5.3	Análise estatística.....	47
6	RESULTADOS E DISCUSSÃO	49
6.1	Desempenho do Modelo Computacional	49
6.2	Avaliação do comportamento dos suínos frente aos recursos climáticos utilizados	53
6.2.1	Análise ambiental.....	53
6.2.2	Análises fisiológicas.....	55
6.2.3	Análise comportamental	57
7	CONCLUSÃO	67
8	REFERÊNCIAS.....	68

1 INTRODUÇÃO E JUSTIFICATIVA

O estado de bem-estar e comportamento animal tem relação estreita com a produção intensiva de suínos e estão associados a saúde dos animais, bem como à qualidade dos seus produtos. Esses temas têm atraído o interesse de pesquisadores dando enfoque aos estudos que minimizem os efeitos negativos da produção intensiva sobre os animais, melhorando o ambiente (BROOM, 1991).

Nesse sentido, estudos sobre o comportamento animal tem agregado importantes informações sobre as respostas e a adaptação dos animais aos respectivos ambientes. Trata-se de uma característica de grande importância na criação de suínos, uma vez que, por meio do comportamento o animal expressa o seu estado em relação ao ambiente (SNOWDON, 1999). A avaliação do comportamento permite interpretar se o animal está em estresse, se está acometido por alguma injúria, se está em encontros agonísticos ou até mesmo com medo das condições de manejo e alojamento aos quais está inserido. Dessa forma, a avaliação das frequências e tempo dispendido em atividades de consumo, ingestão de água, locomoção e postura podem ser indicativos do estado de bem-estar e condições fisiológicas dos animais. Além disso, essa avaliação possibilita conhecer informações sobre alterações ambientais, que podem contribuir para estabelecer estratégias que otimizem o sistema de produção (BROOM, 1991; BROOM; FRASER, 2010).

A avaliação do comportamento tem sido realizada usando principalmente três formas: a visual direta, em que o avaliador está presente no ambiente do animal, sendo essa forma de observar e registrar o comportamento, laboriosa e subjetiva (BROWN et al., 2013), a visual indireta, em que o avaliador registra os dados de comportamento com câmera de vídeo e analisa-os através de observação visual posteriormente; e por método computacional, que utiliza inteligência artificial para identificar e interpretar padrões de comportamentos. Nesse último caso, o resultado positivo dessa avaliação depende da acurácia do modelo utilizado, apresentando como vantagem o diagnóstico em tempo real e sem a interferência do avaliador (BREWSTER et al., 2018).

Dessa forma, considerando que a identificação dos padrões comportamentais podem auxiliar os produtores a gerenciar a granja de forma mais efetiva, métodos de identificação automática em imagens têm surgido em pesquisas científicas com o intuito de substituir as observações comportamentais visuais (TULLO et al., 2017). Entre estes métodos, os modelos baseados em Aprendizagem Profunda (*Deep Learning*) demonstram

potencial para identificação de padrões em vídeo-imagens. A Rede Neural Convolucional (RNC) faz parte das técnicas de Aprendizagem Profunda, sendo capaz de identificar padrões em imagens, como RGB (*Red, Green and Blue*) e Imagem de Profundidade.

Outro aspecto importante na produção intensiva de suínos tem relação com o conforto térmico dos animais. Dessa forma, identificar os recursos climáticos mais adequados para manter o ambiente térmico ideal para os animais passa pela análise do próprio ambiente térmico, bem como pela avaliação das repostas (comportamento) dos animais frente a determinado recurso climático. Diferentes sistemas de resfriamentos estão disponíveis no mercado, desde ventilação forçada até resfriamento evaporativo do ar dentro do galpão (OLIVEIRA et al., 2021).

Muitos pesquisadores tem avaliado o desempenho de animais em relação ao sistema de resfriamento a que estão sujeitos, mas poucos estudos avaliam o comportamento como uma resposta do animal àquele ambiente. Esse tipo de estudo é especialmente importante quando se considera que é por meio do comportamento que o animal irá expressar a sua condição de conforto e bem-estar sob uma condição ambiental específica. Especificamente em relação aos ambientes controlados, onde diferentes sistemas de resfriamento estão disponíveis, pouco se conhece sobre o padrão de comportamento dos animais nos diferentes sistemas de resfriamentos. Esse conhecimento pode trazer grande contribuição para identificar o estado do BEA dos animais em cada sistema de resfriamento, bem como suas condições de conforto térmico, além de estabelecer parâmetros para desenvolvimento dos modelos computacionais que buscam estimar o conforto térmico e o BEA por meio de imagens. Dessa forma, o objetivo deste estudo foi avaliar por meio de ferramenta computacional de vídeo-imagem e dados ambientais, o comportamento de suínos em ambientes com diferentes tipos de resfriamento.

2 HIPÓTESES

A hipótese desse estudo é que a expressão do comportamento do suíno apresenta variações frente a diferentes tipos de recursos de resfriamento ambiental, mesmo em ambientes que apresentem temperaturas e umidades relativas do ar semelhantes. Diante disso, por meio da análise comportamental por ferramentas de vídeo-imagem e de sua relação com a Frequência Respiratória (FR) e Termografia de Infravermelho (TIV), é possível observar um padrão comportamental do suíno que indique a condição de conforto térmico e bem-estar do animal em função de um determinado recurso climático.

3 OBJETIVO

O objetivo deste estudo foi avaliar o padrão das características comportamentais dos suínos, por meio de processamento de imagem, variáveis fisiológicas e dados ambientais, em ambientes com diferentes tipos de sistema de resfriamento, buscando interpretar seu estado de bem-estar e conforto térmico.

3.1 Objetivos específicos

- Orientar, subsidiar e apoiar a construção e avaliação de técnicas de processamento de vídeo-imagens para serem utilizadas no desenvolvimento de um modelo computacional, utilizando rede neural convolucional, para classificar o comportamento de suínos;
- Identificar variações e padrões nos comportamentos posturais (suíno andando, suíno bebendo, suíno comendo e suíno deitado nos diferentes sistemas de resfriamento);
- Investigar a associação do comportamento de suínos, em diferentes ambientes, com características indicativas de conforto térmico, como a temperatura de superfície corporal da nuca (por meio de Termografia de Infravermelho) e a frequência respiratória;
- Associar o comportamento dos suínos com as variáveis ambientais do ambiente a que foram submetidos.

4 REVISÃO BIBLIOGRÁFICA

4.1 Importância do comportamento e bem-estar animal

O comportamento é uma das características fundamentais nas adaptações das funções biológicas, representando a parte do organismo que interage com o ambiente, as quais são fundamentais para o estado de bem-estar em que se encontram (SNOWDON, 1999).

A criação de suínos comerciais em sistemas de confinamento desde seu nascimento até o momento do abate é feita sob produção intensiva. Porém, várias pesquisas detalham que este tipo de criação pode acarretar mudanças severas no comportamento social dos suínos (CARVALHO et al., 2013; FOPPA et al., 2014; GROOT et al., 2001).

Os comportamentos de locomoção, de ingestão de ração e/ou água e postural, bem como as alterações fisiológicas, podem indicar o estado de bem-estar em que o suíno se encontra, permitindo assim, a tomada de decisão pelos produtores em prol da melhoria na produção (POLETTTO, 2010; SOBESTIANSKY; ZANELLA, 2007; ZANELLA, 1995). Dessa forma, o comportamento da permanência do animal no comedouro, intervalo das refeições, o número de refeições diárias contém informações importantes, que podem permitir aos produtores gerenciar melhor sua granja (BROWN-BRANDL et al., 2013). Além disso, o comportamento de beber água dos suínos pode ser indicativo de enfermidade, como distúrbios intestinais e condições de temperatura interna corporal (BIRD; CRABTREE; SCHOFIELD, 2001; KASHIHA et al., 2013).

De acordo com Broom (1986), o bem-estar é o estado em que o animal se encontra em relação às tentativas de se adaptar ao ambiente. O bem-estar engloba aspectos que estão interligados ao funcionamento fisiológico, como por exemplo, aumento da frequência cardíaca, frequência respiratória e o aumento da temperatura retal dos animais e interligado também aos aspectos comportamentais (FOPPA et al., 2014). Os aspectos do comportamento podem ser avaliados por meio de sua expressão sobre a locomoção, postura, comportamentos agressivos, ingestão de ração e água, bem como também variáveis fisiológicas e variáveis ambientais, atuando como indicador de um rico ou pobre estado de bem-estar (ZANELLA, 1995). Um suíno estará em condições adequadas de bem-estar se estiver sadio, confortável, bem alimentado, em segurança, assim podendo expressar seu comportamento, não apresentando dor, medo e ansiedade.

Diversos estudos têm associado os comportamentos com uma série de fatores estressantes, causados por problemas nas instalações, tais como, alta temperatura e umidade, tipo de piso e alta taxa de lotação dentro dos galpões; e no manejo inadequado,

como a ausência de vazão sanitário, falta de vacinação e vermifugação dos animais, acarretando em comportamentos anômalos, como estereotípias, injúrias e angústias.

Segundo o Farm Animal Welfare Council (FAWC, 1992) considera-se que para um bom estado de bem-estar os animais devem estar livres de fome e sede, livres de desconforto físico e térmico, livres de doenças e de fraturas, livres para expressar seu comportamento natural e livres de medo, dor e estresse. A avaliação do bem-estar animal passa pelo conhecimento sobre a espécie em questão, bem como sobre os respectivos comportamentos naturais, emoções que vivenciam, funcionamento do organismo e a interação de todos esses fatores.

Com foco nas cinco liberdades, é possível mensurar o bem-estar desde o nascimento até o abate dos animais, levando em consideração aspectos da alimentação, da postura, do comportamento, dos aspectos ambientais, da área de descanso na baia e do espaço disponível por animal (LUDTKE; CALVO; BUENO, 2014). Os aspectos ambientais são de fácil mensuração e podem ser utilizados como indicadores de bem-estar por meio da avaliação da temperatura e umidade relativa do ar. Porém, é importante incorporar nesses indicadores dados relacionados ao próprio animal, ou seja, características dos animais capazes de expressar sua condição de conforto. Tais características estão relacionadas com as respostas fisiológicas e ou comportamentais, as quais proporcionam informações mais interessantes e precisas para definir o real estado de bem-estar dos animais sob um ambiente específico (LUDTKE; CALVO; BUENO, 2014).

Conforme comentado, os fatores estressantes que podem ocorrer em sistema de produção intensiva, tais como, isolamento social, ausência de substrato, fome, alta densidade e a baixa qualidade do ar, podem levar os animais a redirecionar o seu comportamento natural para vícios, estereotípias ou comportamentos anômalos (MACHADO FILHO; HÖTZEL, 2000) e esses fatores podem prejudicar o desempenho dos suínos. Foppa et al. (2014) e Carvalho et al. (2013) relataram que sistemas intensivos de criação geralmente possuem seus ambientes confinados pobres e estéreis para os animais e por essa razão devem ser vistos com grande atenção para que melhorias possam ser implantadas no confinamento, tornando o ambiente mais propício para os animais, contribuindo para melhorias no seu desempenho e bem-estar.

Santos et al. (2018), avaliou a influência do ambiente térmico no comportamento de suínos em fase de terminação em dois tratamentos, sendo uma baia com lamina d'água e outra baia sem. Observaram que os suínos comeram mais no período da tarde (19%) no tratamento com lamina d'água a uma temperatura corporal superficial de 34,17 °C e permaneceram mais tempo deitados no período da manhã (53,50%) no tratamento com

lamina d'água a uma temperatura corporal superficial de 34,10 °C. Por fim, concluíram que há diferença comportamental entre os tratamentos, no entanto, o tratamento com a lamina d'água proporcionou melhores condições de bem-estar para os animais. Santos et al. (2021), avaliou o comportamento de um grupo de 5 suínos em fase de terminação em relação a três tipos diferentes de enriquecimentos ambientais, sendo corda de sisal, corrente e garrafa pet e observaram que a corda de sisal proporcionou maior comportamento lúdico nos animais e diminuiu o comportamento de ócio.

Dela Ricci et al. (2018a), avaliou o comportamento de seis machos suínos em diferentes tipos de enriquecimento ambiental e observou que o comportamento lúdico foi mais significativo quando usado o pneu como enriquecimento ambiental. Ou seja, os autores concluíram que o comportamento é influenciável pelo ambiente, permitindo assim os suínos demonstrarem mais comportamentos naturais da espécie.

Andrade et al. (2019), avaliou o comportamento de doze suínos em fase de creche distribuídos em dois tratamentos, sendo tratamento 1, baia enriquecida com correntes suspensas e tratamento 2, baia sem enriquecimento. E observaram diferença significativa ($p < 0,05$) para os comportamentos brincando, comendo e mordendo em relação aos tratamentos avaliados. Por fim, concluíram que o comportamento dos suínos foi influenciado pela presença do enriquecimento ambiental.

Sousa et al. (2018), avaliou o comportamento de 20 suínos em fase inicial submetidos a quatro tratamentos, sendo garrafas pet e uso de música clássica. Observaram que houve diminuição dos comportamentos de morder, cheirar, brigar e perseguir no ambiente enriquecido com brinquedo e música clássica. Portanto, os autores concluíram que o ambiente enriquecido pode favorecer o bem-estar de suínos na fase inicial.

Oliveira (2016), avaliou o comportamento de 720 leitões utilizando enriquecimento ambiental, sendo SOE: sem objeto enriquecedor, OEP: com objeto permanente, SOE24: sem objeto enriquecedor com intermitência de 24h e SOE48: sem objeto enriquecedor com intermitência de 48h. O autor observou que houve uma redução nos comportamentos estereotipados entre os tratamentos (SOE: 7,6%; OEP: 6,2%; SOE24: 6,3% e SOE48: 6,5%). E a maior frequência de interação com o objeto enriquecedor, foi nos leitões submetidos a intermitência de tempo, diminuindo os comportamentos estereotipados, favorecendo o bem-estar dos leitões.

Dela Ricci et al. (2018b), avaliou o comportamento de oito fêmeas suínas lactantes em duas baias, sendo uma climatizada com ventiladores e aspersores de água no telhado e a outra sem equipamentos (baia controle). Os comportamentos foram avaliados na primeira semana de lactação nos períodos da manhã, tarde e noite. Com isso, concluíram

que os comportamentos lúdicos, estereotipados, ofego, alimentação, consumo de água e movimentação diferiram estatisticamente entre os tratamentos com melhora significativa do bem-estar das matrizes no ambiente climatizado, principalmente pela diminuição da temperatura ambiental, onde as médias de temperatura na área climatizada foram de 17 e 18 °C e 32 e 34 °C para a baía controle com menores frequências respiratórias, com médias de 38 e 79 batimentos por minuto. Por fim, concluíram que a utilização de ventiladores internamente e aspersores de água no telhado externamente, melhorou o conforto térmico e o bem-estar das fêmeas suínas paridas.

Andersen et al. (2014), avaliou o comportamento de consumo em 52 suínos em crescimento, sendo número de visitas, duração, ingestão de água e variação diurna. Observaram que o comportamento de beber, foi registrado por 4 dias consecutivos e no geral, os suínos passaram 594 segundo no bebedouro durante 24 horas distribuídas em 44 visitas. Durante este período, foi consumido 5 litros de água. Por fim, concluem que existe um padrão comportamental para o comportamento beber, e que as ferramentas de monitoramento são importantes, mas deve-se levar em consideração outros efeitos que possam também alterar esses resultados.

Quiniou et al. (2000a), avaliaram o comportamento de 40 porcas lactantes por 21 dias em cinco tipos de temperaturas ambientes diferentes, sendo 18, 22, 25, 27 e 29°C, com ração *ad libitum*, no qual verificou uma redução no comportamento ingestivo e com redução no consumo de 7,80 Kg para 3,50 Kg entre 18 a 29°C, respectivamente. Isso demonstra que o ambiente térmico influencia diretamente no comportamento de comer dos animais.

Kiefer et al. (2010), relatou que o estresse térmico (31,3 °C) ocasionou inatividade e redução da ingestão de alimentos em 24 machos castrados em fase de crescimento e terminação. Quiniou et al. (2000b), constataram que suínos entre 25 kg e 110 kg aumentavam ou diminuíam a ingestão de alimentos de acordo com a oscilação da temperatura do ar de ($\pm 1,5$ °C) nas temperaturas de 24 ou 28 °C avaliadas, e com isso, a ingestão extra de alimentos nos períodos frios (24 °C) compensou a menor ingestão nos dias mais quentes e por isso, não afetou o desempenho de suínos em fase de crescimento. Sendo assim, a espécie suína, em particular, pode modificar o comportamento e alterar sua fisiologia para adaptar-se aos desafios ambientais (KIEFER et al., 2009; RADOSTITS; MAYHEW; HOUSTON, 2002).

Bernardino et al. (2021) avaliou o comportamento estereotipado da mastigação de 28 marrãs prenhes, utilizando dietas ricas e pobres em fibras. Entretanto, os autores

chegaram à conclusão de que dietas ricas em fibras diminuem esse comportamento estereotipado, ou seja, a nutrição influencia diretamente no comportamento dos suínos.

Oxholm et al. (2014) avaliou o comportamento de suínos em crescimento alimentados com dieta líquida e palha em várias quantidades e frequências. Por fim, concluíram que os suínos foram mais ativos e aumentaram o seu comportamento direcionado a explorar a palha quando receberam 100 g de palha/suíno por dia.

Meunier-Salaün et al. (2014), avaliaram o comportamento de linhagens selecionadas de suínos em crescimento, por 4 dias durante 24 horas. Observaram que os suínos permaneceram maior parte do tempo deitados no período diurno (80%) e (> 89%) noturno, e que passaram menos tempo em pé durante o período de 24 horas (9,7%). E concluíram que suínos possuem esse padrão comportamental da espécie em questão.

Zwicker et al. (2012) avaliaram a influência da acessibilidade da palha nas baias no comportamento exploratório de suínos em terminação. Observaram que o comportamento exploratório seguiu um padrão diário entre as 5 horas de observação e foi aumentando conforme aumentasse a quantidade de palha na baia. Entretanto, concluíram que quanto mais oferece material para enriquecimento ambiental, mais estimula o comportamento exploratório.

Bünger et al. (2015), avaliaram o comportamento agonístico de suínos machos inteiros, fêmeas e machos castrados em terminação. Relataram que machos inteiros apresentaram maior incidência de comportamentos agonísticos após a retirada da metade do lote para abate. Contudo, concluíram que o padrão comportamental da espécie não foi afetada pelo sexo, mas deve-se levar em consideração que o número de animais dentro da baia, pode interferir no comportamento agressivo dos suínos.

Nannomi et al. (2016), avaliaram os efeitos de diferentes tipos de enriquecimento e alguns indicadores de bem-estar de leitões pós-desmame. Por fim, concluíram que a utilização do enriquecimento ambiental aumentou o comportamento exploratório, social e lúdico dos suínos.

Morrone et al., (2021) avaliaram a presença de um suíno mais velho (4 meses de idade) dentro de 4 baias com 24 leitões recém desmamados com 21 dias de idade. E verificou que houve uma melhora no bem-estar dos leitões, devido a presença do animal mais velho, estabelecendo uma hierarquia entre o lote, diminuindo as interações agonísticas. Por fim, concluíram que os suínos são animais que possuem classes sociais dentro do lote e a hierarquia influencia diretamente no comportamento dos animais.

Além do comportamento, aspectos sobre a resposta termorregulatória de suínos também tem sido investigadas para entender como se relacionam com o bem-estar de

suínos. Carvalho, Oliveira e Turco (2004) utilizou a nebulização e a ventilação forçada para avaliar o desempenho e a temperatura da pele de 137 suínos (machos castrados e fêmeas) em fase de terminação, nos períodos entre agosto e outubro, com temperaturas variando de 23,32 à 30,72 °C. Os autores verificaram que no tratamento sem nebulização e ventilação forçada, os animais obtiveram um ganho de peso de 810 g/animal e temperatura da nuca no período da manhã de 35,76 °C e no período da tarde de 35,15 °C. Já no tratamento com nebulização e ventilação forçada, obtiveram um ganho de peso de 818 g/animal e a temperatura da nuca no período da manhã foi de 31,21 °C e no período da tarde foi de 31,04 °C, demonstrando que a utilização da nebulização associada à ventilação forçada melhorou o conforto térmico, mas não melhorou o desempenho dos animais.

Morales et al. (2013) também compararam diferentes sistemas de resfriamento sobre comportamento e desempenho de suínos o efeito dos diferentes sistemas de controle da temperatura ambiental, sendo, sistema climatizado: com placas de resfriamento evaporativo combinado com ventilação de pressão negativa (SCL), sistema refrigerado com saídas de ar frio diretamente em cima das porcas combinadas com manejo de cortinas (SR) e sistema de cortinas (SC) no comportamento de porcas e suas leitegadas. Os autores concluíram que no sistema sistema de cortinas houve uma redução do comportamento de comer comparado ao sistema SCL e SR, e justificaram esse resultado devido ao fato de que nesse ambiente a temperatura crítica superior estava acima da indicada como conforto de 26,8 °C, sobretudo entre 12:00 e 16:00.

Kiefer et al. (2009) avaliou as respostas comportamentais de 24 suínos machos castrados mantidos em diferentes temperaturas, divididos em dois tratamentos com 21,5°C e 31,3°C. O autores observaram que no ambiente de 31,3°C, os suínos permaneceram menos tempo em pé, mais tempo deitado, menos tempo no comedouro, mais tempo no bebedouro e mais tempo dormindo em relação aos suínos mantidos no ambiente de conforto de 21,5°C, indicando alterações comportamentais em função do ambiente térmico.

Com isso, tendo em vista que a avaliação do comportamento apresenta a vantagem de ser uma técnica não invasiva, rápida e prática, mensurando o estado do indivíduo em relação ao seu ambiente (HÖTZEL; MACHADO FILHO, 2004), diversas pesquisas tem sido realizadas para avaliar a interação do animal com o ambiente.

4.2 Interação ambiente térmico – animal

Com relação à interação ambiente-animal, um dos aspectos importantes diz respeito sobre as consequências sobre o desempenho dos animais. Sabe-se que o desempenho

está associado com fatores genéticos, de manejo, nutrição e sanidade, que, por sua vez, estão correlacionados a fatores climáticos, especialmente temperatura do ar e umidade relativa do ar (CARVALHO; OLIVEIRA; TURCO, 2004). O ambiente térmico que circunda os animais domésticos possui influência direta na quantidade de calor trocado entre o animal e o ambiente. O ambiente térmico é constituído por elementos meteorológicos, tais como, temperatura do ar, umidade relativa, ventilação e radiação, sendo estes principalmente que afetam, direta ou indiretamente, o desenvolvimento, o crescimento e o bem-estar dos animais (BAÊTA; MEADOR; SHANKLIN, 1997).

As variáveis meteorológicas interagem conjuntamente e a avaliação por meio de uma só variável não permite conclusão. Com isso, foram desenvolvidos vários índices de conforto térmico, tais como ITU (Índice de Temperatura e Umidade) (NWSCR, 1976) e ITGU (Índice de Temperatura de Globo e Umidade) desenvolvido por Buffington et al. (1981). Devido à elevação da temperatura do ar em torno do globo negro, principalmente pelas temperaturas do solo aquecido e superfície inferior da cobertura da instalação, que se elevam com o aumento da irradiação solar global, os valores de ITGU atingem o máximo entre as 12 e 14 horas (SAMPAIO, 2004). Assim, o globo negro recebe mais calor do ambiente, o que acarreta na elevação da sua temperatura e conseqüentemente um acréscimo nos valores do ITGU.

De acordo com Voermans e Monteny (1997), o ambiente térmico dentro da instalação suinícola é dependente do dimensionamento das instalações, escolha do tipo de piso e de cobertura utilizados. É difícil determinar qual a temperatura exata de conforto de um suíno em relação às variáveis de idade, raça, dieta, manejo e instalações, e por isso, os estudos sempre se referem a uma zona de conforto, ou seja, a uma faixa de temperatura e umidade do ar máxima e mínima ideal (Tabela 1).

Tabela 1 – Zona de termoneutralidade das matrizes, leitões e suínos até a terminação

Categoria	Temperatura			
	Ideal (°C)		Crítica (°C)	
	Máxima	Mínima	Máxima	Mínima
Matrizes	18	12	30	0
Leitões/nascimento	32	30	35	15
1 semana	28	27	35	13
2 semana	26	25	35	13
3 semana	24	22	35	12
4 semana	23	21	31	10
5/6 semanas	22	20	30	8
20-30 kg	20	18	27	8
30-60 kg	18	16	27	5
60-100 kg	18	12	27	4

Fonte: Adaptado de Sampaio (2004).

Observa-se na Tabela 1 que existe uma grande variação entre as temperaturas de conforto para as diferentes fases da vida do suíno. Pode-se destacar a fase inicial de vida dos animais, em que a saúde e o desenvolvimento dos leitões recém-nascidos têm seu melhor resultado em ambiente entre 30° e 32°C enquanto suínos em crescimento (4 semanas) apresentam melhor desempenho em temperaturas do ar entre 21° e 23°C e animais em terminação, dos 60 aos 100kg, apresentam melhor desempenho em temperaturas entre 12° e 18°C (SCHORMANN; HOY, 2006). Segundo Mangold, Hazen e Hays (1967), condições ambientais inadequadas afetam negativamente a produção ocasionando um crescimento mais lento, prejudicando a qualidade da carne com acréscimo de gordura e espessura de toucinho.

Dessa forma, é de grande importância estudos que contribuem para o entendimento da troca de calor entre o animal e o meio ambiente (MCGOVERN; BRUCE, 2000). A troca de energia do suíno com o ambiente ocorre nas formas de calor sensível e calor latente. Quando os fluxos de calor ocorrem devido ao gradiente de temperatura (entre o animal e o ambiente) são chamados de sensíveis e podem ocorrer na forma de condução, convecção e radiação. Fluxos de calor dependentes do gradiente de pressão de vapor d'água são chamados de latentes ou evaporativos (FERREIRA, 2011). Há dois processos básicos para a liberação do calor latente, sendo evaporativo ou pela respiração. Os suínos recorrem principalmente ao processo da respiração, pois suas glândulas sudoríparas são afuncionais. Portanto, o suíno não conta com a sudorese como mecanismo de proteção às

altas temperaturas, utilizando, exclusivamente o ofego e as mudanças comportamentais. A eficiência desta troca é afetada, principalmente, pela temperatura do ar, pela velocidade do vento e pela umidade relativa do ar (BORTOLOZZO; GAGGINI; WENTZ, 2011).

Bortolozzo, Gaggini e Wentz (2011) observaram que a elevação da UR de 45 para 90% a uma temperatura de 21°C, foi responsável pela redução das perdas de calor em até 8%, ou seja, a maior umidade relativa, considerando uma mesma temperatura do ar, reduziu as trocas de calor entre o animal e ambiente. Já Ferreira (2011) observaram que, para suínos de 30 a 60 kg mantidos em ambientes com temperaturas acima da temperatura crítica superior (21 e 32°C) e sob uma mesma condição de umidade relativa, a eliminação de calor latente foi intensificada, observando aumento da frequência respiratória de 44 para 82 movimentos por minuto. Outros estudos também observaram elevação da frequência respiratória em função de uma maior temperatura do ar (MANNO et al., 2006; TAVARES et al., 2000).

Manno et al. (2006) aferiram as temperaturas do reto, da nuca, da paleta e do pernil dos suínos e observaram que os animais sob estresse térmico apresentaram valores das temperaturas superficiais (nuca, paleta e pernil), coletados por meio de termômetro de infravermelho e termômetro clínico aproximadamente 9,5% superiores aos animais submetidos ao conforto térmico.

Kammersgaard, Malmkvist, Pedersen (2013), utilizou a termografia de infravermelho para avaliar o estado térmico de suínos neonatos com base na temperatura da superfície. E concluíram que a termografia tem relação com o estado térmico dos leitões recém-nascidos.

Sykes et al. (2012) utilizaram a termografia de infravermelho para identificar o estro de 32 marrãs distribuídas em 2 tratamentos, sendo um as fêmeas alimentadas com soja crua e o outro farelo de soja. Por fim, observaram temperaturas elevadas através da termografia de infravermelho na região da vulva no período de estro e concluíram que a termografia de infravermelho é uma ferramenta não invasiva que auxilia na avaliação do estro.

Dela Ricci et al. (2019) utilizou a termografia de infravermelho em porcas lactantes e seus leitões para avaliar o estresse térmico em baias livres de gaiolas na maternidade. A mesma utilizou 26 porcas em lactação e 281 leitões até 21 dias de idade em dois tratamentos: baias resfriadas com ventiladores e aspersores de água no telhado e baias não resfriadas. As imagens termográficas foram coletadas pela manhã e à tarde. Os autores concluíram que a superfície mais quente das porcas foi a região da glândula mamária e a mais fria a vaginal. Nos leitões, a região mais quente foi a cabeça e a mais fria, o focinho.

No entanto, mesmo que o sistema de refrigeração tenha reduzido a temperatura do ar das baias resfriadas, concluíram que isso não foi o suficiente para reduzir a temperatura corporal superficial das porcas e leitões desse tratamento durante a fase de lactação.

Boileau et al. (2019), avaliou o comportamento agonístico de 46 suínos em fase de crescimento utilizando termografia de infravermelho. E observou um aumento da termografia de infravermelho no momento do comportamento agonístico, portanto, concluem que a utilização da termografia de infravermelho como ferramenta para avaliar estresse nos suínos é válida.

Yáñez-Pizaña et al. (2019), avaliou o efeito de diferentes tipos de enriquecimento ambiental utilizando termografia de infravermelho em 64 leitões na área ocular, orelhas e nariz. Os autores encontraram diferenças significativas entre os tratamentos e por fim concluíram que a termografia de infravermelho pode ser utilizada para avaliar as diferenças de temperaturas em leitões.

Pulido-Rodriguez et al. (2017) utilizaram a termografia de infravermelho na região ocular juntamente com a análise do cortisol salivar para avaliar o estresse térmico em leitões na fase de creche. Os autores avaliaram 66 leitões uma vez por semana durante 7 semanas em dois horários, às 7:00 e 15:00. O cortisol salivar apresentou correlação alta e positiva ($P < 0,05$) com a temperatura ocular (0,89). Concluindo que a termografia de infravermelho na região ocular pode ser um indicador do estado de bem-estar em leitões na fase de creche.

Adamec et al. (1997) apud Knizkova (2007) estudaram a possibilidade de reduzir o estresse pelo calor em suínos na terminação durante o período de verão com o uso de pad cooling. As alterações na temperatura da superfície do corpo foram medidas pela termografia de infravermelho. Os autores concluíram que o resfriamento evaporativo levou a diminuição do estresse por calor nos suínos e ao aumento do crescimento e da conversão alimentar.

Soerensen e Pedersen (2015) concluíram em seu trabalho que mais pesquisas sobre o uso da termografia de infravermelho para a rastreabilidade da saúde do suíno são necessárias para que com seu uso possam ser feitos diagnósticos precisos e confiáveis. Segundo Cook et al. (2015), a termografia de infravermelho pode ser utilizada como ferramenta de triagem para doenças febris em suínos. Qin et al. (2017), em seus estudos relatou que a termografia de infravermelho pode ser usada para monitorar as atividades dos suínos em pesquisas sobre comportamento e bem-estar animal.

Brown-Brandl et al. (2013) realizaram um estudo utilizando a termografia de infravermelho para avaliar as temperaturas de superfície de suínos em crescimento

baseado em mudanças nas imagens térmicas captadas a diferentes temperaturas. Os autores concluíram que a temperatura de superfície foi significativamente afetada pela temperatura ambiente.

No Brasil, a suinocultura, por ter como característica principal a produção intensiva, há necessidade de se manter a temperatura ambiente interna adequada. O tipo de construção (galpões abertos, semiabertos, fechados com ou sem isolamento térmico), de aspecto físico (tipo de piso e área útil das baias, por exemplo), de telhado (material das telhas, com ou sem lanternim, com ou sem sistema de arrefecimento), de climatização (ventilação natural, mecânica ou mista, com ou sem arrefecimento) e de manejo é que determinam o ambiente interno das instalações. Além disso, é importante observar a insolação (orientação da obra) e os ventos dominantes, que também influenciam as trocas de ar da construção (SILVA, 2008).

Adicionalmente, como o clima brasileiro é predominantemente tropical, a atenuação da temperatura é essencial em instalações pecuárias em todo o país. Dessa forma, a ventilação é um importante parâmetro entre os aspectos ambientais e é essencial para promover o conforto térmico e um ar mais limpo nas instalações de confinamento. A ventilação artificial é adotada sempre que os meios naturais não proporcionam o índice de renovação de ar ou a redução da temperatura necessários, apresentando a vantagem de ser independente das condições atmosféricas. Como as médias anuais brasileiras de temperatura estão acima de 25°C, a ventilação artificial torna-se imprescindível na grande maioria das instalações pecuárias (SILVA, 2008).

Diferentes sistemas de resfriamento estão disponíveis no mercado, desde convecção forçada até resfriamento evaporativo do ar dentro do galpão. Muitos pesquisadores têm avaliado o desempenho de animais em relação ao sistema de resfriamento a que estão sujeitos. Sartor et al. (2003) compararam o sistema de resfriamento evaporativo a um grupo controle (sem sistema) para suínos em fase de terminação, e constataram que a conversão alimentar do grupo tratado foi 75% melhor que o grupo controle, 2,83 e 3,32 respectivamente. Também observaram que o ganho de peso diário foi superior nos animais submetidos ao sistema de resfriamento evaporativo, sendo de 0,950 kg para o grupo controle e 1,050 kg para o grupo tratado. Huyn et al. (2005) concluíram que o resfriamento por aspersão de água ou por lâmina d'água reduziram o estresse por calor em suínos, uma vez que os animais expostos nesse ambiente apresentaram menor taxa de respiração, menor temperatura superficial, melhor conversão alimentar e maior ganho de peso diário do que os animais do grupo controle. Turner et al. (1997) reportaram um aumento de 10,6% no ganho de peso diário de suínos na fase de

crescimento/terminação submetidos a sistemas de resfriamento em comparação aos suínos do grupo controle. Carvalho, Oliveira e Turco (2004), comparando o uso da nebulização ao da ventilação forçada em suínos na fase de terminação, a uma temperatura média de 26,3 °C (variando de 23,3 a 30,7 °C) e uma umidade relativa média de 64,5%, observaram a melhora no conforto (temperatura da pele), como também uma melhora no comportamento social, diminuição na competição pelo comedouro e pelo bebedouro nos horários mais quentes do dia. Ao final, esse estudo sugeriu que a nebulização seria o recurso mais indicado para suínos.

Embora os diferentes sistemas de resfriamento tenham um objetivo comum, a atenuação da temperatura no interior das instalações, eles podem ser percebidos pelos animais de forma diferente, sendo que essa percepção pode ser expressa por meio do seu comportamento (NÄÄS, 2007). Dessa forma, os efeitos dos sistemas de resfriamento sobre as variáveis de desempenho, condições físicas e fisiológicas dos animais têm sido comparados de acordo com a ausência versus presença de climatização, porém, são escassos os estudos que comparam diferentes recursos de climatização e os avaliam sobre o ponto de vista do comportamento animal.

Nesse sentido, considerando que muitos são os fatores que interferem nas ótimas condições de criação dos sistemas suínoclas e por consequência no bem-estar animal, reforça-se a importância da avaliação do conforto térmico por meio do comportamento animal, sobretudo quando se considera que o animal expressa por meio do seu comportamento as respostas a todos esses fatores. Dessa forma, atualmente, pesquisas têm sido realizadas para desenvolver modelos computacionais para interpretação rápida das características de comportamento e do ambiente. Tais modelos, além de identificar automaticamente os comportamentos, procuram possibilitar a indicação de situações de bem-estar dos animais.

4.3 Ferramenta computacional para avaliação do comportamento

Pesquisas recentes buscam viabilizar ferramentas computacionais para sistemas de gerenciamento contínuo totalmente automatizados através de visão computacional, fornecendo informações e alarmes confiáveis com base no monitoramento contínuo de animais (TULLO et al., 2017). Tecnologias baseadas em visão computacional podem ser utilizadas para converter em tempo real o comportamento dos animais, capturados com câmeras e sensores, em informações relevantes, possibilitando atuação de sistemas

automatizados de controle e monitoramento on-line (TULLO et al., 2017). Este tema pode ser aplicado a diferentes aspectos do manejo, com foco tanto no ambiente quanto nos animais, individualmente ou até mesmo no rebanho inteiro (JONES; WATHES; WEBSTER, 2010), gerenciamento de estratégias alimentares, controle da taxa de crescimento e monitoramento da atividade animal (FONTANA et al., 2015). Além disso, trata-se de uma tecnologia automatizada não-invasiva, podendo fornecer alerta precoce para a identificação de problemas de produção animal, saúde e bem-estar nas fazendas (GUARINO et al., 2017). Comparado à pontuação manual, a visão computacional também pode permitir o monitoramento contínuo tanto de medidas quantitativas como qualitativas, para vários aspectos do comportamento do animal, através da aplicação de métodos e técnicas de identificação, extração e interpretação de características de cada cena registrada (TULLO et al., 2017).

4.3.1 Inteligência Artificial

Os sistemas de visão computacional necessitam de algoritmos associados ao sistema de captura de imagens para identificar elementos específicos e determinadas características de interesse nessas imagens. Métodos baseados em Inteligência Artificial (IA) tem se destacado para tal aplicação. A IA se caracteriza por algoritmos que simulam a capacidade humana de perceber, raciocinar, resolver e tomar decisões. Um dos ramos da IA bastante utilizados em sistemas de visão de computacional é a Aprendizagem de Máquina (*Machine Learning*), que contempla técnicas baseados em algoritmos construídos pela exposição a exemplos (treinamento). Sendo fortemente impulsionada pelos avanços na capacidade de processamento computacional (FERNANDES et al., 2018), as ferramentas de Aprendizado de Máquina têm sido utilizadas para análise de grandes volumes de dados e para proposição de soluções para problemas em sistemas complexos em diversas áreas, incluindo a produção agropecuária (KAMILARIS; PRENAFETA-BOLDÚ, 2018; KAMILARIS; KARTAKOULLIS; PRENAFETA-BOLDÚ, 2017). Diversos estudos tem demonstrado o potencial dessas técnicas para interpretar características comportamentais e prever alguns parâmetros produtivos, bem como de bem-estar animal (PANDORFI et al., 2011; TULLO et al., 2017).

Um outro componente importante da IA é a Aprendizagem Profunda (*Deep Learning*), no qual a Rede Neural Convolutiva (RNC) está inserida (SILVA; PERES; BOSCARIOLI, 2016). A RNC é uma ferramenta computacional que permite a construção

de modelos computacionais para reconhecimento de padrões em vídeo-imagens compostos por cenas ou imagens complexas de ambientes pouco-estruturados. Sua aplicação permite a extração de informações de cenas, que associadas a outras informações, podem alimentar bases de dados de grande volume (*Big Data*). A RNC é uma evolução das Redes Neurais Artificiais, que na sua forma clássica, são compostas por neurônios artificiais (perceptron) interconectados e que tem como inspiração os mecanismos de funcionamento dos neurônios humanos que formam redes complexas capazes de extrair, processar e analisar informações do ambiente externo (LECUN; BENGIO; HINTON, 2015; PATRÍCIO; RIEDER, 2018; SILVA; PERES; BOSCARIOLI, 2016). A aplicação da Aprendizagem Profunda tem sido largamente estudada e utilizada na agricultura, com aplicações para identificação de doenças, inspeção de qualidade no cultivo de vegetais e em estudos para avaliar os padrões de aplicações de fertilizantes agrícolas (KAMILARIS; PRENAFETA-BOLDÚ, 2018; KAMILARIS; KARTAKOULLIS; PRENAFETA-BOLDÚ, 2017; MARCAL; CUNHA 2019; SHAH; JAIN; MAHESHWARI, 2016; ZAREIFOROUGH et al., 2015).

4.3.2 Redes Neurais Convolucionais

As RNC possuem arquiteturas multicamadas que combina a extração de características (camadas concolucionais) com o aprendizado de máquina realizado por camadas de RNA. Um dos benefícios do uso da RNC é reduzir o número de parâmetros que deverão ser ajustados em relação aos algoritmos clássicos de processamento de imagens e então minimizar o processo de treinamento. Uma característica importante desta arquitetura está relacionada com sua invariância à escala, à translação e à outras transformações, ou seja, ela consegue reconhecer padrões de forma mais robusta e automática (VIEIRA; SILVA; BARBOSA FILHO, 2010).

Uma das principais vantagens de utilização da RNC é a independência de um trabalho mais profundo de tratamento da imagem, conduzindo a um menor esforço humano no desenvolvimento de suas funcionalidades básicas. As suas camadas convolucionais (*Convolutional layer* – CL) são conjuntos de filtros 3D não lineares que percorrem sequencialmente os dados de entrada (ou camada anterior) e então produzem ou extraem matrizes chamadas mapas de características ou mapas de padrões (*feature maps*) em que filtros 2D (*kernel*) são aplicados em unidades da matriz. Cada tipo de filtro pode extrair um tipo diferente de padrão (SILVA; PERES; BOSCARIOLI, 2016).

Durante o processo de treinamento, esses filtros são ajustados automaticamente para que sejam ativados na presença de características relevantes, como orientação de bordas ou manchas de cores (KARPATHY, 2017). Em cada camada convolucional, diversos filtros são usados e os mapas de características produzidos são então empilhados, formando uma matriz 3D para imagens 2D ou uma matriz 4D para imagens 3D (LECUN; BENGIO; HINTON, 2015).

O processo de aprendizagem de uma RNC recebe como entrada uma imagem digital com três canais RGB (*Red, Gray and Blue*). Duas etapas de convolução e uma de agrupamento são responsáveis pela extração de padrões. Dependendo do tipo de problema analisado, mais etapas de convolução e agrupamento podem ser aplicadas sobre as matrizes. As informações extraídas na primeira etapa serão utilizadas como entradas na etapa de classificação (KVAM; KONGSRO, 2017).

Diversas aplicações de RNC e de outras ferramentas de aprendizado profundo tem sido desenvolvidas como, por exemplo: sistemas de identificação individual de bovinos com a análise de imagem do focinho (KUMAR et al., 2018), sistemas de reconhecimento individual de suínos (HANSEN et al., 2018), análise automática de bem-estar (NILSSON et al., 2015), predição de gordura intramuscular em suínos vivos, por meio de análise de imagens de ultrassom (KVAM; KONGSRO, 2017), sistema de reconhecimento de posturas em imagens de infravermelho (Kinect) de porcas em lactação (ZHENG et al., 2018), estimativa de peso (KONGSRO, 2014), identificação do comportamento agressivo (OCZAK et al., 2014) e locomoção de suínos utilizando RNC (KASHIHA et al., 2014).

Além das aplicações citadas, a utilização desta técnica também pode ser útil para extrair padrões que estimem a situação de conforto térmico por meio da identificação postura e comportamentos de suínos (MISIMI et al., 2017). Ressalta-se que o sistema possui a vantagem de evitar etapas prévias de processamento de imagens, podendo assim operar com imagens mais brutas e menos padronizadas em relação aos métodos clássicos de processamento de imagens.

Outro fator muito importante na utilização das RNC é a utilização de bancos de dados balanceados que permitem a identificação de padrões e sua classificação em categorias com maior facilidade. Essa característica é importante para a maior parte das ferramentas de aprendizado de máquina, como aponta Fonolla et al. (2019), que encontrou melhores acurácias em seus modelos quando o banco de dados estava balanceado (Tabela 2).

Tabela 2 – Comparação de banco de dados desbalanceados e balanceados

Desbalanceado	Acurácia
k-Nearest Neighbor	77,3%
Naives Bayes	81,3%
Random Forest	83,7%
Support Vector Machine	80,3%
Balanceado	Acurácia
k-Nearest Neighbor	79,8%
Naives Bayes	82,8%
Random Forest	83,3%
Support Vector Machine	83,3%

Fonte: Adaptada de Fonolla et al. (2019).

5 MATERIAL E MÉTODOS

Para esse estudo foi utilizado o banco de imagens oriundo do trabalho de pesquisa de doutorado da Dra. Débora Caroline Gonçalves de Oliveira, realizado no setor de suinocultura da prefeitura do campus Fernando Costa, na Faculdade de Zootecnia e Engenharia de Alimentos, da Universidade de São Paulo na cidade de Pirassununga – SP. A coleta de vídeo-imagens e dados experimentais ocorreram entre fevereiro a maio de 2015.

Dessa forma, a fim de facilitar o entendimento, esse item abordará alguns detalhes sobre o período experimental (item 5.1) com os suínos, ocorrido em 2015 e que gerou as vídeo-imagens (utilizadas para desenvolvimento do presente estudo) e, posteriormente, abordará detalhes sobre o desenvolvimento da ferramenta computacional, bem como a avaliação do comportamento animal (item 5.2). Portanto, nesse último item serão detalhados: os métodos e formas de análises para identificação e avaliação do comportamento dos suínos, bem como a estatística utilizada para avaliação, frente à diferentes recursos de resfriamento.

5.1 Período experimental

5.1.1 Instalação e Sistemas de Resfriamento

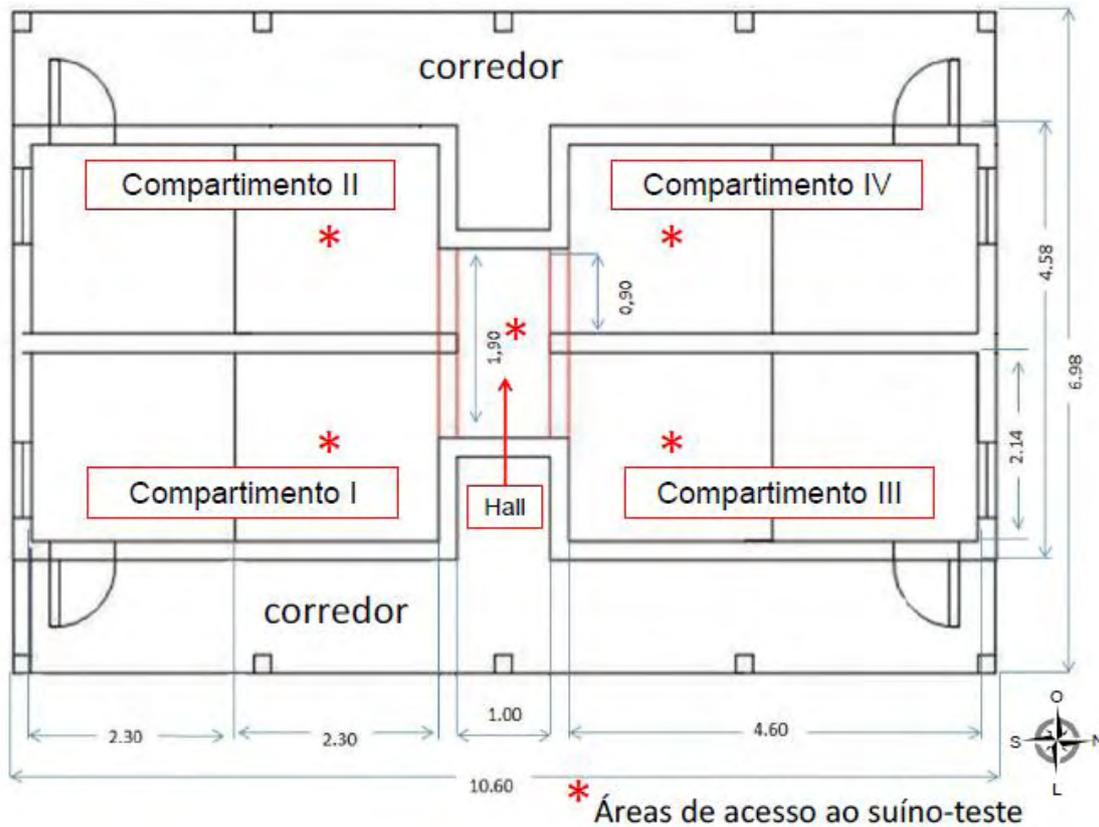
Foram utilizados 8 suínos híbridos Pen Ar Lan, sendo 4 machos castrados e 4 fêmeas com aproximadamente 95 dias de idade e alojados em quatro baias idênticas (2 animais/baia) em uma instalação denominada de Câmara de Preferência Ambiental (CPA) por 42 dias (Figuras 1 e 2). As baias da CPA foram equipadas com cochos de alimentação, bebedouros, e diferentes sistemas de resfriamento, os quais eram responsáveis por manter os ambientes com temperatura do ar e umidade relativa semelhantes nas quatro baias, entre 18 a 21°C e 60 a 70% respectivamente. Cada baia foi equipada com câmera de vídeo no teto (Ccd Sony infrared – Penko) para o monitoramento dos comportamentos durante 42 dias, sendo gravadas 10 horas por dia, das 8 às 18 horas.

Figura 1 – Vista da CPA



Fonte: Própria autoria.

Figura 2 – Desenho ilustrativo da vista superior da CPA



Fonte: Oliveira (2015).

Os sistemas de resfriamento eram controlados por meio dos limites de temperatura e umidade relativa do ar, monitorados por sensores instalados dentro de cada compartimento, os quais indicavam quando um equipamento de resfriamento deveria ser acionado ou desligado.

Tais limites foram definidos de acordo com os observados em literaturas como faixa de conforto para os suínos nessa fase de crescimento (SILVA, 1999; TOLON et al., 2010). Dessa forma, uma vez que a temperatura no compartimento atingia o valor mínimo de temperatura programado (18 °C), o equipamento daquele galpão era desativado até que a temperatura aumentasse até 21 °C, e então o sistema era ativado novamente. Se a umidade relativa atingisse o valor máximo de 70%, o equipamento evaporativo daquele compartimento era desativado até que a umidade relativa reduzisse para 60%. Isso se dava por meio da interrupção dos aspersores/nebulizadores ou acionamento dos exaustores. Os sistemas eram acionados em cada um dos compartimentos de modo independente. Dessa forma, os controladores usavam os dados de entrada dos sensores de temperatura e umidade relativa como referência para ativar/desativar os sistemas de resfriamento. A

iluminação dos compartimentos se deu por meio de lâmpadas incandescentes (40W) por um período de 13:00 horas (06:00 – 19:00) e com intensidade aproximada de 50 lux.

Os 4 sistemas estudados foram:

Tratamento Nebulização e Ventilador (NV): composto por sistema de nebulização, com bico nebulizador da marca Tritec com pressão de trabalho de 10,34 Bar e vazão de 75 mL minutos⁻¹, associado à ventilador Twister, da marca Arge, com vazão 3240 m³h⁻¹ (ou 0,9 m³s⁻¹) e rotação de 1150 rpm. A intermitência de operação do sistema de nebulização foi operada com um ciclo de 2 minutos pulverizando água no ambiente a uma taxa de 0,55 L minutos⁻¹ e 2 minutos inativo para redução do uso de água e para um melhor controle da temperatura ambiente. Ambos os equipamentos foram configurados para manter a temperatura e a umidade relativa do ambiente, conforme citado anteriormente.

Tratamento Ventilação forçada (V): composto apenas de ventiladores Twister, da marca Arge, com vazão 3240 m³h⁻¹ (ou 0,9 m³s⁻¹) e rotação de 1150 rpm. O ventilador foi configurado para manter a temperatura e a umidade relativa do ambiente.

Tratamento Aspensor (A): composto somente por sistema de aspersão, com bico aspensor com pressão de trabalho de 6,89 a 10,34 Bar e vazão de 0,4 a 0,6 L min⁻¹. Uma vez acionado, o aspensor operou de modo intermitente entre 2 minutos aspergindo água sobre os animais a uma taxa de 41,0 mL minutos⁻¹ e 30 min inativo, para permitir a evaporação da água na superfície corporal.

Tratamento Aspensor e Ventilador (AV): Semelhante ao sistema A, porém com o ventilador Twister, da marca Arge, possuía vazão 3240 m³h⁻¹ (ou 0,9 m³s⁻¹) e rotação de 1150 rpm. Uma vez acionado, o aspensor operava com 2 minutos aspergindo água sobre os animais a uma taxa de 41,0 mL min⁻¹ e 20 min inativo para permitir a evaporação da água na superfície corporal. O ventilador era acionado quando a temperatura estava superior a 21°C e desligado quando a temperatura atingisse 18°C.

Em cada compartimento da CPA existia também um Exaustor modelo Multifan 130 com cone e 3 pás e volume de ar de 45.600 m³h⁻¹. Os Exaustores operavam com o inversor em sua metade da capacidade, 30 Hz, velocidade aproximada de 1,2 m s⁻¹, ligado 2 min e desligado 1 min, a cada hora e um controlador SMAAI, modelo 02, que era interligado a todos os sistemas de resfriamentos, bem como também a Bomba de água Booster de 1,5 CV.

5.1.2 Coleta de dados

5.1.2.1 Ambiente térmico

O monitoramento do ambiente térmico no interior da CPA ao longo do período experimental deu-se com o auxílio de Loggers (marca HOBO, modelo U12-012), com coletas a cada 15 minutos. Foram utilizados dois loggers (1 para backup de segurança) (Figura 3).

Figura 3 – Vista do compartimento experimental com destaque para os sensores loggers



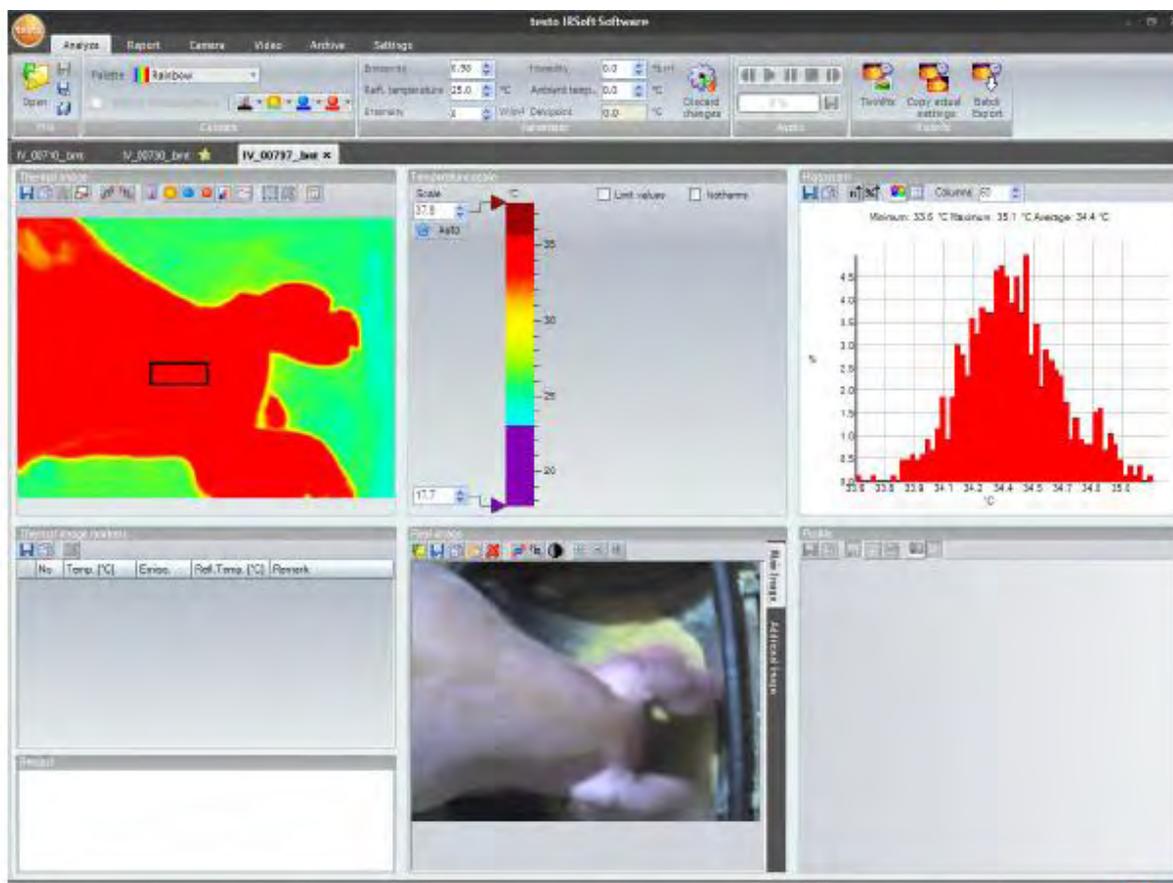
Fonte: Oliveira (2015).

5.1.2.2 - Variáveis fisiológicas

Foram medidas as temperaturas de superfície corporal de todos os suínos por meio de câmera termográfica (TESTO® 872) uma vez ao dia, entre 14 e 15 horas durante os 42 dias. A região corporal escolhida para a coleta foi a nuca. A câmera de infravermelho foi calibrada com emissividade de 0,95 para todas as imagens, seguindo a mesma metodologia de Pacheco et al. (2020). As imagens foram avaliadas pelo software IRsoft®,

selecionando-se uma área menor, específica da nuca, e obtendo-se a temperatura média, mínima e máxima daquela região (Figura 4).

Figura 4 – Imagem ilustrativa do programa com a seleção da área a ser analisada



Fonte: Oliveira (2015).

Também foi coletada a frequência respiratória dos suínos nos mesmos dias em que foram coletadas as temperaturas de superfície da nuca. A frequência respiratória foi coletada por meio da contagem dos movimentos do flanco durante 15 s e o valor obtido multiplicado por quatro para obtenção da frequência por minuto. Essa medida foi coletada antes da coleta das imagens termográficas, de forma a não provocar distúrbio aos animais e não interferir nas medidas. A observação visual era feita pela abertura da entrada de ar de cada compartimento.

5.2 Construção do modelo baseado em RNC

Optou-se por iniciar as atividades desse estudo voltadas para o desenvolvimento do modelo computacional para identificação e classificação de comportamentos de suínos nas vídeos-imagens. O experimento com 42 dias de confinamento e monitoramento por vídeo

por 10 horas por dia, gerou 840 vídeos, com aproximadamente 420 horas de gravação no total. Na etapa de orientação, construção e avaliação de técnicas de processamento de vídeo-imagem foi realizada a conversão dos vídeos para um formato adequado, além de utilizar técnicas de captura das imagens, e a etapa de rotulagem (*labeling*). Essas técnicas estão detalhadas a seguir:

Conversão dos vídeos:

Os vídeos, originalmente em formato AVI, foram convertidos no software MovieMaker para o formato MP4, pois o formato original não era reconhecido pelas bibliotecas de imagem em linguagem de programação Python 3.5.4 rcl, que foi utilizada para construção do modelo de avaliação.

Captura das imagens de vídeos:

A partir da conversão em MP4, os vídeos foram processados por um *script* (*rotina programa de computador de linguagem interpretada*) em linguagem de programação Python 3.5.4 rcl, desenvolvida pelo grupo RAEB (Robótica e Automação para Engenharia de Biosistemas). Nesse processo foi realizada a extração de imagens (frames) do vídeo em momentos específicos, sendo que a cada movimento que o suíno realizava, era extraída uma imagem do vídeo automaticamente.

Labeling

A ação denominada *Labeling* é uma etapa importante para construção do modelo, uma vez que é nela que é realizada a identificação e rotulagem dos comportamentos em cada imagem.

Para essa etapa foi utilizado um outro *script*, desenvolvido em ambiente *Matlab R2015a*, pelo grupo RAEB, para auxiliar no processamento para selecionar, recortar, e rotular os recortes de cada imagem de maneira manual de acordo com o conteúdo visualizado (classes de comportamento), gerando recortes ou quadros no tamanho de 200x200 (Figura 5) e 100x100 (Figura 6) referentes aos comportamentos: suíno andando, suíno bebendo, suíno comendo, suínos comendo juntos, suíno deitado, suínos deitado juntos (Tabela 3) e mais o conjunto ambiente vazio (que denomina o espaço vazio dentro do compartimento, sem suíno).

Tabela 3 – Etograma de trabalho para avaliação comportamental (classes)

Comportamento dos suínos (classes)	Descrição
Andando	Suíno se locomovendo dentro do compartimento, explorando ou fuçando, com a cabeça abaixada ou pra cima.
Bebendo	Suíno bebendo água no bebedouro.
Comendo	Suíno comendo ração no comedouro.
Comendo Junto	Dois suínos comendo ração ao mesmo tempo no comedouro.
Deitado	Suíno deitado, em ócio ou dormindo em decúbito ventral ou lateral sem movimentação.
Deitado Junto	Dois suínos deitados, em ócio ou dormindo junto próximos em decúbito ventral ou lateral sem movimentação

Fonte: Própria autoria.

Figura 5 – Recorte do suíno no tamanho de 200x200

Fonte: Própria autoria.

Figura 6 – Recorte do suíno no tamanho de 100x100

Fonte: Própria autoria.

A partir dessas imagens foram gerados dois bancos de dados de imagens. O primeiro com um número variado entre as classes comportamentais, sendo o banco de dados desbalanceado (Tabela 4). O segundo foi gerado a partir do banco de dados

desbalanceado através da exclusão de algumas imagens do banco, buscando assim uma padronização entre as classes comportamentais como, por exemplo, nas imagens do animal comendo e andando, uma vez que o número de imagens dessa classe era muito superior ao número de imagens do animal bebendo. Desta forma, a partir do banco desbalanceados gerou-se um banco de dados balanceado (Tabela 5), que foi gerado considerando todas as imagens em cada classe de comportamento.

Portanto, os dois bancos foram utilizados para a construção dos dois modelos computacionais baseados em RNC. Para isso foi utilizado o protocolo de validação cruzada no qual 60% das imagens foram aplicadas para o treinamento da RNC, 20% para validação e 20% para o teste, selecionados de forma aleatória, para os dois modelos.

Tabela 4 – Total de imagens desbalanceadas em cada classe de comportamento utilizada para cada etapa do treinamento, da validação e de teste do processamento da rede neural convolucional

Classes	Treinamento	Validação	Teste	Total
Ambiente Vazio	10398	3466	3466	17330
Andando	5463	1821	1822	9106
Bebendo	2468	822	824	4114
Comendo	6394	2131	2133	10658
Comendo Junto	1021	340	342	1703
Deitado	1966	655	657	3278
Deitado Junto	1378	459	460	2297
Total	29088	9694	9704	48486

Fonte: Própria autoria.

Tabela 5 – Total de imagens após o balanceamento, em cada classe e para cada etapa do treinamento, da validação e de teste do processamento da rede neural convolucional

Classes	Treinamento	Validação	Teste	Total
Ambiente Vazio	3600	1200	1200	6000
Andando	3600	1200	1200	6000
Bebendo	2462	820	822	4104
Comendo	3600	1200	1200	6000
Comendo Junto	1015	338	340	1693
Deitado	1960	653	655	3268
Deitado Junto	1372	457	458	2287
Total	17609	5868	5875	29352

Fonte: Própria autoria.

A biblioteca Keras para Python foi utilizada para implementar a arquitetura de camadas da RNC, a qual foi configurada pelos seguintes comandos:

```
Conv2D(64, kernel_size = (7, 7), strides = 1, activation = 'relu')
```

```
MaxPooling2D(pool_size = (2, 2))
```

```
BatchNormalization()
```

```
Conv2D(32, kernel_size = (5, 5), activation = 'relu')
```

```
MaxPooling2D(pool_size = (2, 2))
```

```
BatchNormalization()
```

```
Flatten()
```

```
Dense(1000, activation = 'relu')
```

```
Dense(label_count, activation = 'softmax')
```

A construção dos *scripts* para os modelos baseados em RNC foi realizada pelo grupo RAEB do Departamento de Engenharia de Biosistemas (ZEB).

5.2.1 Construção da *Frequency Counter* (FC) e Avaliação do comportamento animal

Para avaliação comportamental foram analisados os seguintes comportamentos: Suíno andando, suíno bebendo, suíno comendo e suíno deitado durante 10 horas, das 08:00 às 18:00 por 42 dias. Para isso, foi feito um etograma comportamental (Tabela 6).

Tabela 6 – Etograma comportamental para o desenvolvimento da ferramenta FC

Comportamento dos suínos (classes)	Descrição
Andando	Suíno se locomovendo dentro do compartimento, explorando ou fuçando, com a cabeça abaixada ou pra cima.
Bebendo	Suíno bebendo água no bebedouro.
Comendo	Suíno comendo ração no comedouro.
Deitado	Suíno deitado, em ócio ou dormindo em decúbito ventral ou lateral sem movimentação.
Manejo	Coleta de imagens da termografia de infravermelho e frequência respiratória.

Fonte: Própria autoria.

Uma outra ferramenta computacional denominada FC (*Frequency Counter*) foi construída para a identificação do comportamento de suínos por meio dos vídeos, bem como para contabilizar o tempo em que cada animal dispndia em determinado comportamento. A ferramenta computacional criada pela equipe de pesquisadores do RAEB que desenvolveu dois *scripts*, um para registrar o comportamento animal em cada *frame* e outro para gerar um relatório de contabilização do tempo dispendido em cada comportamento. Ambos foram desenvolvidos em ambiente do software *Matlab* R2015a, uma vez que esse software oferece os recursos para manipulação de vídeos e criação de interfaces de usuário.

A FC permite ao usuário assistir um vídeo e inserir manualmente o comportamento que o suíno está expressando naquele determinado momento (realizando a rotulagem ou *labels*) e registrando esses frames (quadros ou imagens que compõem um vídeo). Para a facilitar a identificação individual, a ferramenta pode ser configura com os nomes e comportamentos dos suínos com cores específicas. Neste trabalho foram utilizados suíno 2 (S2) na cor verde e o suíno 3 (S3) azul (Figura 7).

Figura 7 - Configuração de cores, nomes e comportamentos dos animais para o *labeling*. As cores são representadas em valores RGB normalizados

```

% Colors, objects and behaviors to label
myApp.labelInfo = {[1.00 0.00 0.00] 'S1' {'Andando' 'Bebendo' 'Comendo' 'Dormindo' 'Ausente'}};
                  [0.00 1.00 0.00] 'S2' {'Andando' 'Bebendo' 'Comendo' 'Dormindo'};
                  [0.00 0.00 1.00] 'S3' {'Andando' 'Bebendo' 'Comendo' 'Dormindo'};

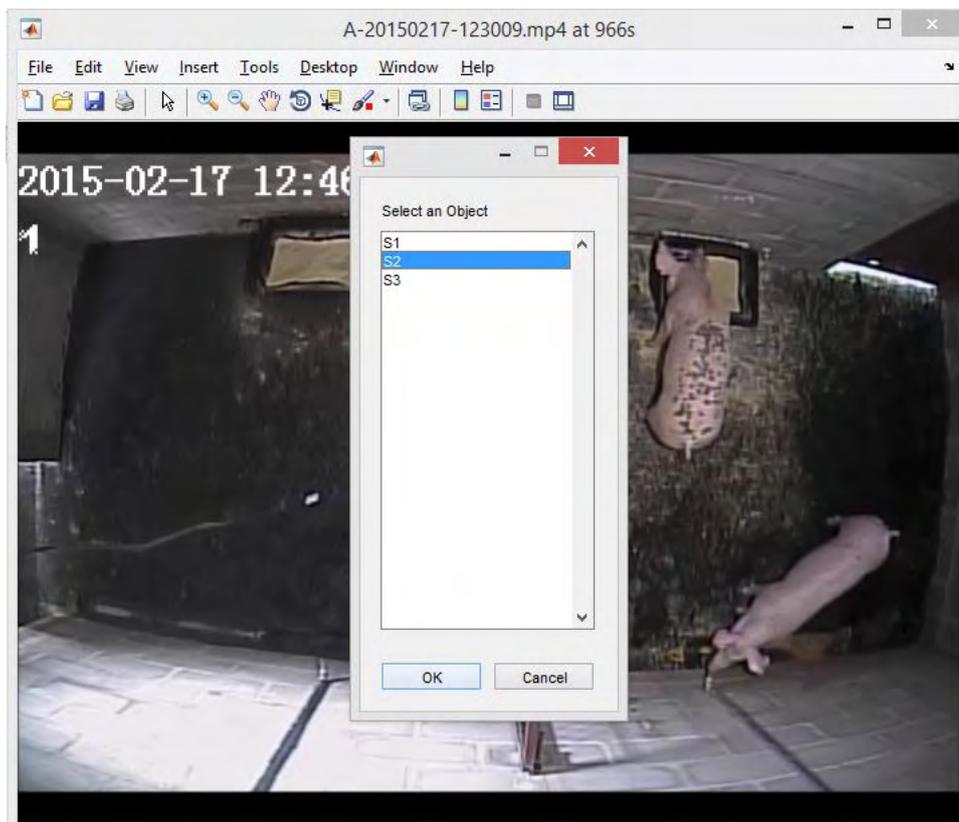
```

Fonte: Própria autoria.

A taxa de exibição e o passo de leitura de *frames* são especialmente importantes porque afetam diretamente o trabalho de *labeling* e nesse estudo foi definido uma taxa de 40 frames por segundo (fps). Sendo assim, considerando um vídeo com duração de 30 minutos com taxa de 40 frames por 40 fps, um usuário assistiria 72.000 frames ao longo desse tempo. Configurando a taxa de exibição em 80 frames por 40 fps e um passo de leitura de 80 frames, o mesmo usuário assistirá apenas 900 *frames* ao longo de 1 minuto e 30 segundos. Desde que não haja perda de qualidade no *labeling*, assistir menos *frames* em menos tempo tornou o trabalho mais produtivo, principalmente quando o número de vídeos é grande, como era o caso do presente estudo.

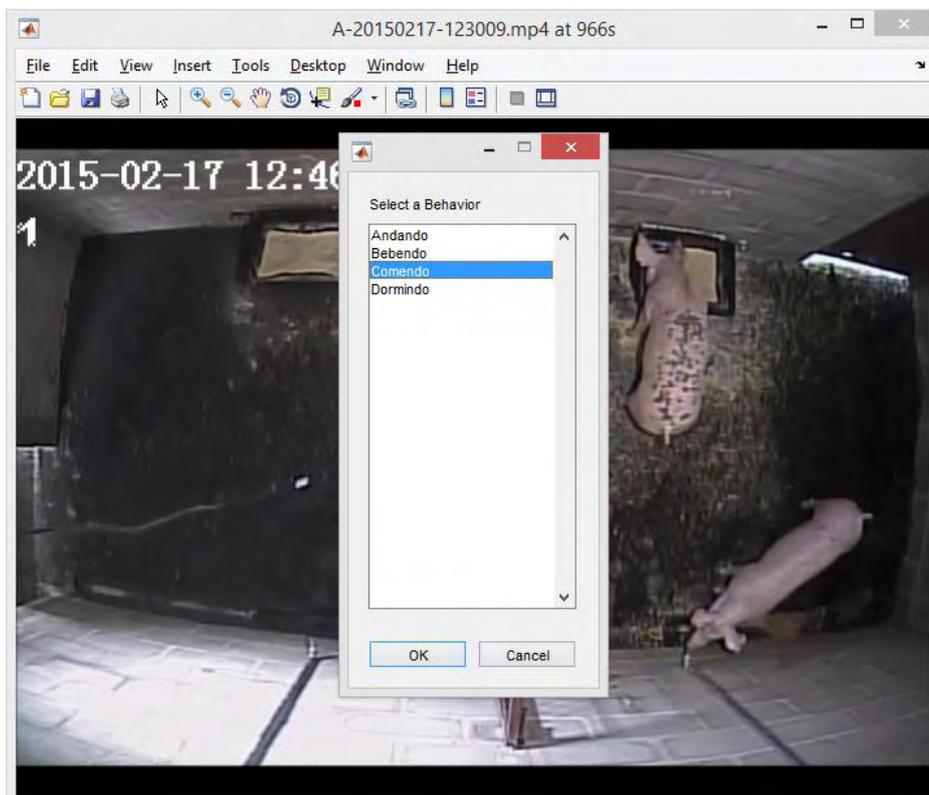
O funcionamento da FC é relativamente simples. Quando iniciado, o vídeo entra em modo de exibição automática, estampando os *labels* que já foram definidos anteriormente. Para inserir um novo *label*, o usuário precisa pausar o vídeo com a tecla [Space], selecionar em algum ponto do *frame* (preferencialmente próximo ao animal) e selecionar o animal em questão em uma nova janela de visualização (*popup*), (Figura 8). Em seguida, o usuário seleciona o comportamento apropriado em uma nova janela *popup*, conforme Figura 9. Dessa forma, um novo *label* é inserido no ponto indicado no *frame*, conforme Figura 10.

Figura 8 - Seleção do animal para inserir um novo *label*



Fonte: Própria autoria.

Figura 9 - Seleção do comportamento para inserir um novo *label*



Fonte: Própria autoria.

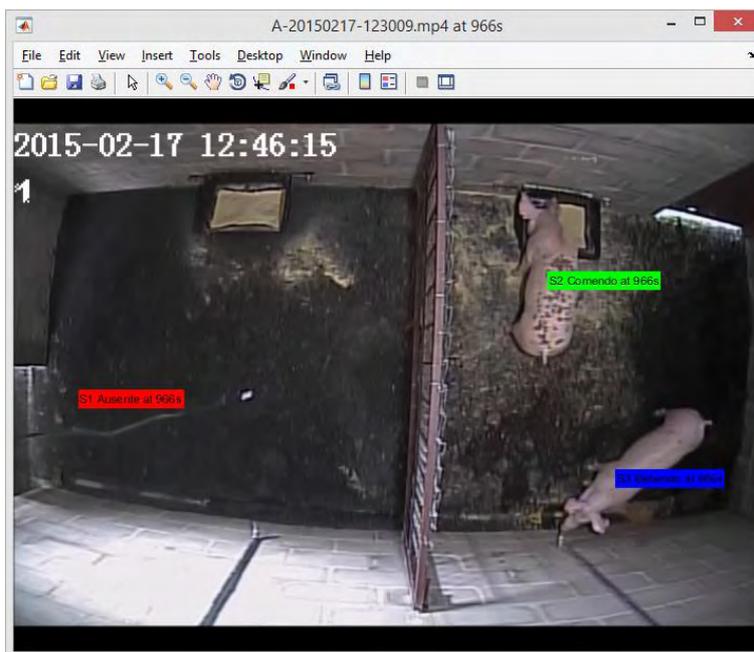
Figura 10 – Novo *label* inserido no ponto indicado



Fonte: Própria autoria.

O processo se repete até que todos os comportamentos desejados sejam identificados (Figura 11). Se desejar deletar algum *label*, basta clicar sobre o mesmo com o botão direito do mouse.

Figura 11 - *Frame* com todos os comportamentos anotados



Fonte: Própria autoria.

O usuário pode teclar [Space] para voltar a assistir o vídeo em modo de exibição automática ou usar as teclas [Left] ou [Right] para retroceder ou avançar *frames*, ou ainda, usar as teclas [Home] ou [End] para ir ao início ou fim do vídeo.

Uma vez inserido um *label*, o mesmo permanece “em vigor” até o que um novo *label* seja inserido, em razão da mudança de comportamento do animal.

Como resultado do *labeling* é gerado um arquivo-texto, com campos separados por tabulações, contendo o momento (em segundos a partir do início e término do vídeo), a coordenada, o nome do animal e o respectivo comportamento para cada *label* definido no vídeo (Figura 12). Dessa forma, o segundo script, gera um relatório final (Figura 13) com as informações de frequências e tempos para cada tipo de comportamento avaliado. Os dados para esse estudo compreenderam a avaliação dos vídeos de 42 dias do experimento, com gravações de 10 horas diárias (das 8:00 às 18:00).

Figura 12 - Dados do *labeling*, armazenados em arquivo-texto com campos separados por tabulações

Time	X	Y	Object	Behavior
0	346	278	S1	Dormindo
0	413	207	S2	Dormindo
0	469	167	S3	Dormindo
882	326	262	S1	Andando
890	27	320	S1	Ausente
936	468	149	S3	Andando
942	457	227	S2	Andando
948	480	175	S2	Comendo
948	572	180	S3	Comendo
952	627	158	S3	Andando
966	538	383	S3	Bebendo

Fonte: Própria autoria.

Figura 13 – Relatório final gerado pela ferramenta FC

	A	B	C	D	E	F
1	Chamber	Date	Object	Behavior	Frequency	Time
2	B	14/03/2015	S3	Dormindo	18	04:28:02
3	B	14/03/2015	S3	Bebendo	12	00:07:03
4	B	14/03/2015	S3	Andando	11	00:13:32
5	B	14/03/2015	S3	Comendo	14	01:05:37
6	B	14/03/2015	S3	Manejo	2	00:05:34
7	B	14/03/2015	S2	Dormindo	24	05:15:20
8	B	14/03/2015	S2	Andando	13	00:16:00
9	B	14/03/2015	S2	Bebendo	9	00:05:30
10	B	14/03/2015	S2	Comendo	11	00:17:24
11	B	14/03/2015	S2	Manejo	2	00:05:34
12	B	14/03/2015	S1	Ausente	14	04:45:14
13	B	14/03/2015	S1	Andando	6	00:03:16
14	B	14/03/2015	S1	Comendo	20	00:55:00
15	B	14/03/2015	S1	Bebendo	15	00:05:32
16	B	14/03/2015	S1	Manejo	2	00:10:46
17						

Fonte: Própria autoria.

5.3 Análise estatística

O delineamento experimental utilizado foi inteiramente casualizado, sendo 4 tratamentos com 42 dias de repetição para cada grupo de 2 animais, com medidas repetidas no tempo. Os tratamentos foram os 4 tipos de sistema de resfriamento: Aspensor (A), Ventilador (V), Aspensor mais Ventilador (AV) e Nebulizador mais Ventilador (NV).

Primeiro passo foi o desempenho dos modelos computacionais com dados balanceados e não balanceados, os mesmos foram avaliados a partir de uma matriz de confusão, que permite comparar a classificação real com a predita pelo modelo computacional utilizando dos dados da base de dados reservada para teste. A partir da matriz confusão é possível extrair informações úteis para avaliar a qualidade das respostas, pois permite verificar a quantidade ou porcentagem de acertos e erros do classificador em relação a um conjunto de dados de teste. A acurácia, eq. (3), a precisão, eq. (4), sensibilidade, eq. (5) e medida F1, eq. (6) foram os parâmetros calculados a partir de dados extraídos das matrizes de confusão. Tais métricas foram observadas de acordo com Sokolova e Lapalme (2009), conforme descrito a seguir.

Acurácia: valor que indica a eficácia geral do classificador.

$$\text{Acurácia} = \frac{\text{Classificações corretas}}{\text{Total de predição}} \quad (3)$$

Precisão: dos dados que o modelo indicou para determinada classe, quantos foram classificados corretamente. A precisão indica a capacidade do classificador não classificar dados incorretos como positivos.

$$\text{Precisão} = \frac{\text{Classificações corretas/classe}}{\text{Total de predições / classe estimada}} \quad (4)$$

Sensibilidade: em relação aos dados corretos, quanto o classificador conseguiu encontrar. A sensibilidade mostra a habilidade do classificador de encontrar todos os exemplos corretos para cada classe.

$$\text{Sensibilidade} = \frac{\text{Classificações corretas/classe}}{\text{Total de predições / classe real}} \quad (5)$$

Medida F1: é uma combinação dos resultados de precisão e sensibilidade (média harmônica) e reflete o quão eficiente é o classificador para prever os dados na presença de classes desbalanceadas, ou seja, quando existem classes com quantidades de exemplos menores que as outras.

$$\text{Medida F1} = \frac{2 * \text{precisão} * \text{sensibilidade}}{\text{Precisão} + \text{sensibilidade}} \quad (6)$$

Segundo passo foi organizar os dados para análise estatística. Nesse passo, percebeu-se que durante os 42 dias do experimento houve falhas de gravação, causando a perda de alguns registros de gravação. Nesse caso, optou-se por retirar os dias que não estavam completos, ou seja, os dias analisados foram aqueles em que os vídeos compunham 10 horas de gravação. Com isso os dias analisados foram 28 dias (não consecutivos) com 10 horas de gravação/dia.

Para a análise estatística dos dados comportamentais (28 dias) foi utilizado o procedimento MIXED do SAS, onde o efeito fixo é o tipo de sistema de resfriamento e os efeitos aleatórios são os animais e o dia de coleta. As médias do comportamento, das variáveis ambientais e das variáveis fisiológicas foram obtidas através do LSMEANS pelo teste de Tukey a 5% de significância.

6 RESULTADOS E DISCUSSÃO

6.1 Desempenho do Modelo Computacional

Os modelos computacionais foram desenvolvidos com base nos dois bancos de dados, sendo um banco de dados desbalanceado e outro banco com dados balanceado, conforme comentado no Material e Métodos.

Os resultados dos modelos computacionais foram avaliados por meio da matriz de confusão, que indica os erros, os acertos para cada comportamento e a precisão final do modelo.

Na tabela 7 observa-se a matriz confusão resultante do banco de dados desbalanceado.

Tabela 7 – Matriz confusão resultante do teste do modelo criado com banco de dados desbalanceado

Pre Real	Amb	And	Beb	Com	Com Jun	Dei	Dei Jun	Sen %
Amb	3461	4	0	1	0	0	0	99,9
And	3	1802	0	1	0	9	7	98,9
Beb	0	1	823	0	0	0	0	99,9
Com	3	45	0	2076	7	1	1	97,3
Com Jun	0	0	0	1	340	0	1	99,4
Dei	0	10	0	0	0	647	0	98,5
Dei Jun	0	2	1	0	0	1	456	99,1
Prec.	99,8	96,7	99,9	99,9	98,0	98,3	98,1	99,0

Predito (Pre): Classificação estimada pela rede neural convolucional. Real: Classificação baseada na classe de comportamento. Estipulado: Ambiente Vazio (Amb), Andando (And), Bebendo (Beb), Comendo (Com), Comendo Junto (Com Jun), Deitado (Dei), Deitado Junto (Dei Jun). Precisão (Prec): Dados que o modelo indicou para determinada classe. Sensibilidade (Sen): Quanto o classificador conseguiu encontrar.

Fonte: Própria autoria

Analisando os dados preditos pelo classificador RNC na diagonal da Tabela 7, observou-se uma acurácia do modelo de 99,0%. Este valor corresponde às proporções corretas preditas em relação ao conjunto de quadros que são apurados com valores iguais ao real.

Analisando os comportamentos preditos pelo modelo (nas colunas da Tabela 7), o classificador RNC acertou com precisão de 96,7% para o comportamento andando, 99,9% para o bebendo, 99,9% para o comendo, 98% para o comendo junto, 98,3% para o deitado e 98,1% para o deitado junto. Os comportamentos que apresentaram maiores precisões

foram o bebendo e comendo. Já o comportamento andando foi o que apresentou menor precisão em relação aos demais comportamentos, sendo que a maior parte dos erros dos quadros em que os animais estavam andando foram interpretadas pelo modelo como se estivessem comendo (45), seguido de deitado (10), ambiente (4), deitado junto (2) e bebendo (1). Observou-se que ainda o modelo confundiu o comportamento deitado junto com os comportamentos andando (7), comendo (1) e comendo junto (1). No caso dos comportamentos andando e deitado junto que obtiveram menores precisões, uma forma de melhorar é incluir no banco de dados um número maior de imagens com variações desses comportamentos (posição deitado com as patas esticadas ou dobradas), aumentando a possibilidade de aprendizagem do algoritmo. Além disso, como um avanço do presente estudo, em uma outra etapa de modelagem poderá ser adicionado outro script que identificará o comportamento “deitado junto” e “andando” após a avaliação de pelo menos dois frames seguintes. Dessa forma, o algoritmo só identificaria o animal em posição “deitado junto” se no próximo frame não for identificada movimentação daqueles animais. De outra forma se houver movimentação do animal, o algoritmo poderá interpretar que o animal está andando com maior confiança.

Diversos trabalhos têm utilizado tecnologias de visão computacional baseada em inteligência artificial para detectar e classificar comportamentos de suínos, tais como agressividade de suínos em crescimento (CHEN et al., 2019; VIAZZI et al., 2014), comportamento de porcas lactantes (LAO et al., 2016) e estimar peso de suínos (CONDOTTA et al., 2018; JUN et al., 2018), indicando que uso de imagens para detectar comportamento tem grande potencial. Porém diferente dos trabalhos citados acima, que utilizaram câmeras 3D para captação das imagens, o presente estudo procurou desenvolver um modelo utilizando imagens de câmera 2D. Uma vantagem de se utilizar a câmera 2D está relacionada com a melhor qualidade da imagem para ambientes abertos ou seja, em ambientes com entrada de luz, o que é bastante comum nas instalações em ambientes de clima tropical. Além disso, o custo de aquisição de câmeras 2D pode ser uma atrativo maior favorecendo sua utilização na produção animal, sobretudo quando se considera que a adoção de novas tecnologias passa necessariamente pela boa relação custo-benefício para sua implantação.

Outros trabalhos utilizando aprendizagem profunda em seus modelos para classificar comportamento de suínos também encontraram precisões elevadas, porém um pouco menores às observadas no presente estudo. Chen et al. (2020b) desenvolveram modelo classificador para avaliar o comportamento individual de comer de suínos no estágio de creche. Os autores utilizaram video-imagem de 8 suínos monitorados durante 3 dias por 8

horas diárias e observaram precisão de 95,9% no modelo desenvolvido. Já Zheng et al. (2018) desenvolveu modelo para reconhecimento automático de 5 classes de posturas de porcas lactantes soltas nas baias com suas leitegadas usando kinect e obtiveram precisão geral do modelo de 87,1%.

Posteriormente, a fim de investigar se um banco de dados contendo um número similar de imagens em cada uma das classes comportamentais (banco de dados balanceados) poderia melhorar a acurácia do modelo de predição foi gerado um novo banco de dados. O novo banco de dados, com 29.352 imagens foi desenvolvido passando por um processo de exclusão manual de algumas imagens, buscando balancear o número de imagens entre as classes de comportamento.

Na tabela 8 observa-se a matriz confusão resultante do banco de dados balanceado.

Tabela 8 – Matriz confusão resultante do teste do modelo criado com banco de dados balanceado

Pre Real	Amb	And	Beb	Com	Com Jun	Dei	Dei Jun	Sen %
Amb	1193	2	0	5	0	0	0	99,4
And	1	1194	0	0	0	3	2	99,5
Beb	0	1	821	0	0	0	0	99,9
Com	0	2	1	1194	2	1	0	99,5
C Jun	0	0	0	6	333	0	1	97,9
Dei	1	7	0	0	0	647	0	98,8
Dei Jun	0	3	0	0	0	0	455	99,3
Prec	99,8	98,7	99,9	99,1	99,4	99,4	99,4	99,4

Predito (Pre): Classificação estimada pela rede neural convolucional. Real: Classificação baseada na classe de comportamento estipulado: Ambiente Vazio (Amb), Andando (And), Bebendo (Beb), Comendo (Com), Comendo Junto (C Jun), Deitado (Dei), Deitado Junto (Dei Jun). Precisão (Prec): Dados que o modelo indicou para determinada classe. Sensibilidade (Sen): Quanto o classificador conseguiu encontrar.

Fonte: Própria autoria

O modelo gerado com o banco de dados balanceados obteve uma precisão de 99,4%, correspondente às proporções corretas preditas em relação ao conjunto de imagens com valores iguais ao real. Provavelmente a melhora na precisão geral desse modelo, comparado ao modelo anterior (dados desbalanceados), foi em razão do novo banco de imagens conter uma quantidade equilibrada de imagens entre as classes comportamentais. De fato, estudos com RNC (FONOLLA et al., 2019; SWARUP et al., 2021) têm utilizado

com sucesso técnicas computacionais com abordagem para aumentar o número de imagens para combater o desequilíbrio entre as classes avaliadas e assim melhorar o desempenho do respectivos modelos. Fonolla et al. (2019) observou uma melhora na precisão do modelo com conjunto de dados balanceado (precisão de 90%) comparado ao banco desbalanceado (precisão de 88%).

Analisando os comportamentos preditos na coluna (Tabela 9), o classificador RNC acertou com precisão de 98,7% o comportamento andando, 99,9% o bebendo, 99,1% o comendo, 99,4% o comendo junto, 99,4% o deitado e 99,4% o deitado junto. Os comportamentos que obtiveram maiores precisões foram o comportamento bebendo, seguido dos comportamentos comendo junto, deitado e deitado junto. Novamente o comportamento andando foi o de maior relevância na contabilização da porcentagem de erro, uma vez que a maior parte dos quadros de erro em que os animais estavam andando foram interpretadas pela rede como se estivessem deitado (7), deitado junto (3) e comendo (2). Embora esse segundo modelo tenha melhorado a precisão da detecção do comportamento andando (98,7%) em relação ao modelo anterior (96,7%), ainda existem algumas melhorias que poderão ser feitas futuramente para melhorar essa detecção. Uma das explicações para o maior erro nesse comportamento em relação aos demais pode estar no fato da classe do comportamento andando ser muito relativa quando comparada aos outros comportamentos, uma vez que estes possuem características específicas, que auxiliam na identificação do comportamento. Um exemplo é o comportamento comendo, o qual é identificado pela rede com o animal comendo com a cabeça dentro do comedouro. Outro exemplo é o comportamento bebendo, no qual é identificado com o animal bebendo com o focinho encostado no bebedouro tipo chupeta. Entretanto, o comportamento andando não possui determinada característica específica, ele pode ser facilmente confundido pela RNC com o comportamento deitado, que mostra apenas no labeling um suíno, sem alguma outra característica ou objeto que auxilie na identificação comportamental desta classe. E conseqüentemente, esses erros, acabam afetando diretamente a acurácia final do modelo. Para uma suposta melhoria deve-se treinar mais a RNC com variedades diferentes de imagens para a classe de comportamento andando, identificando o posicionamento das patas por exemplo, onde sempre que o animal estiver andando, ele estará com as patas esticadas, assim mostrando para o modelo, que existem algumas especificidades nas imagens de suíno andando. Além disso, conforme comentado no modelo anterior, pode-se trabalhar na inclusão de novos scripts que avaliam os frames posteriores, os quais podem identificar com maior precisão se o animal está parado ou andando.

Outros autores como Zhang et al. (2019) propuseram o desenvolvimento de um algoritmo de aprendizagem profunda para detectar comportamento de beber em porcas e observaram precisão de 96,5%. Chen et al. (2020b) e Chen et al. (2020a) também desenvolveram algoritmo baseado em deep learning para reconhecer o comportamento de comer (CHEN et al., 2020b) e beber (CHEN et al., 2020a) de suínos em fase de creche e obtiveram precisão de 95,6% e 93,6%, respectivamente. Yang, Xiao e Lin (2018) também encontraram valores de precisão próximos ao do presente trabalho, sendo 99,6% para o comportamento de comer, utilizando um número reduzidos de imagens em seus banco de dados.

No presente estudo, o algoritmo desenvolvido com dados balanceados apresentou resultados de precisão pouco acima dos observados nos estudos prévios citados acima. Destaca-se que as diferenças de resultados entre os estudos, além das próprias ferramentas computacionais, deve considerar diversos fatores que estão relacionadas às características das instalações, uma vez que o tipo de cama, piso, tipo de comedouro e bebedouro, grades divisórias dentro das baias e pontos cegos das câmeras podem acarretar erros no momento da detecção dos comportamentos. Além disso, fatores relacionados à genética (raça) e densidade animal também podem influenciar a performance do modelo. Dessa forma, usar vídeos diferentes, com variação de alguns desses fatores durante a fase de treinamento pode resultar em modelos mais robustos usando o algoritmo proposto no presente estudo em trabalhos futuros.

Resultados parciais sobre esse tema foram publicados no *V Workshop Internacional de Ambiência de Precisão (2019)*, ocorrido em Campinas/SP, e intitulados “Avaliação do banco de dados de imagem usando rede neural convolucional” e “Construção de um algoritmo classificador de comportamento de suínos usando vídeo imagens”.

6.2 Avaliação do comportamento dos suínos frente aos recursos climáticos utilizados

6.2.1 Análise ambiental

Na tabela 9 estão descritos os dados climáticos observados nos 4 tratamentos.

Tabela 9 – Dados de temperatura do ar e umidade relativa do ar para os tratamentos Aspersão (A), Nebulização e Ventilação (NV) Aspersão e Ventilação (AV) e Ventilação (V). Os dados estão demonstrados em média \pm erro padrão

Ambiente climático	Tratamento ¹				EP ²	P ³
	A	AV	V	NV		
Temperatura do ar (°C)						
Média	23,7	23,7	23,5	23,5	0,22	0,92
Mínima	19,9	20,2	19,8	19,8	0,32	0,78
Máxima	28,1	28,0	28,2	28,0	0,24	0,95
Umidade Relativa (%)						
Média	81,7	81,9	81,2	82,5	0,83	0,73
Mínima	65,0	65,2	64,1	66,1	1,32	0,75
Máxima	93,8	95,2	94,6	95,3	0,46	0,08
Índice de Temperatura e Umidade (ITU)						
Média	67,2	67,4	67,3	67,1	0,06	0,05
Mínima	62,9	63,1	62,8	62,7	0,30	0,77
Máxima	73,7	73,6	73,9	73,5	0,40	0,85

¹Tratamento: A = (Aspersor) AV = (Aspersor e Ventilador); V = (Ventilação Forçada); NV = (Nebulização e Ventilador).

²EP: erro padrão da média.

³Valor de $p < 0,05$ apresenta diferença significativa entre as médias pelo teste de Tukey.

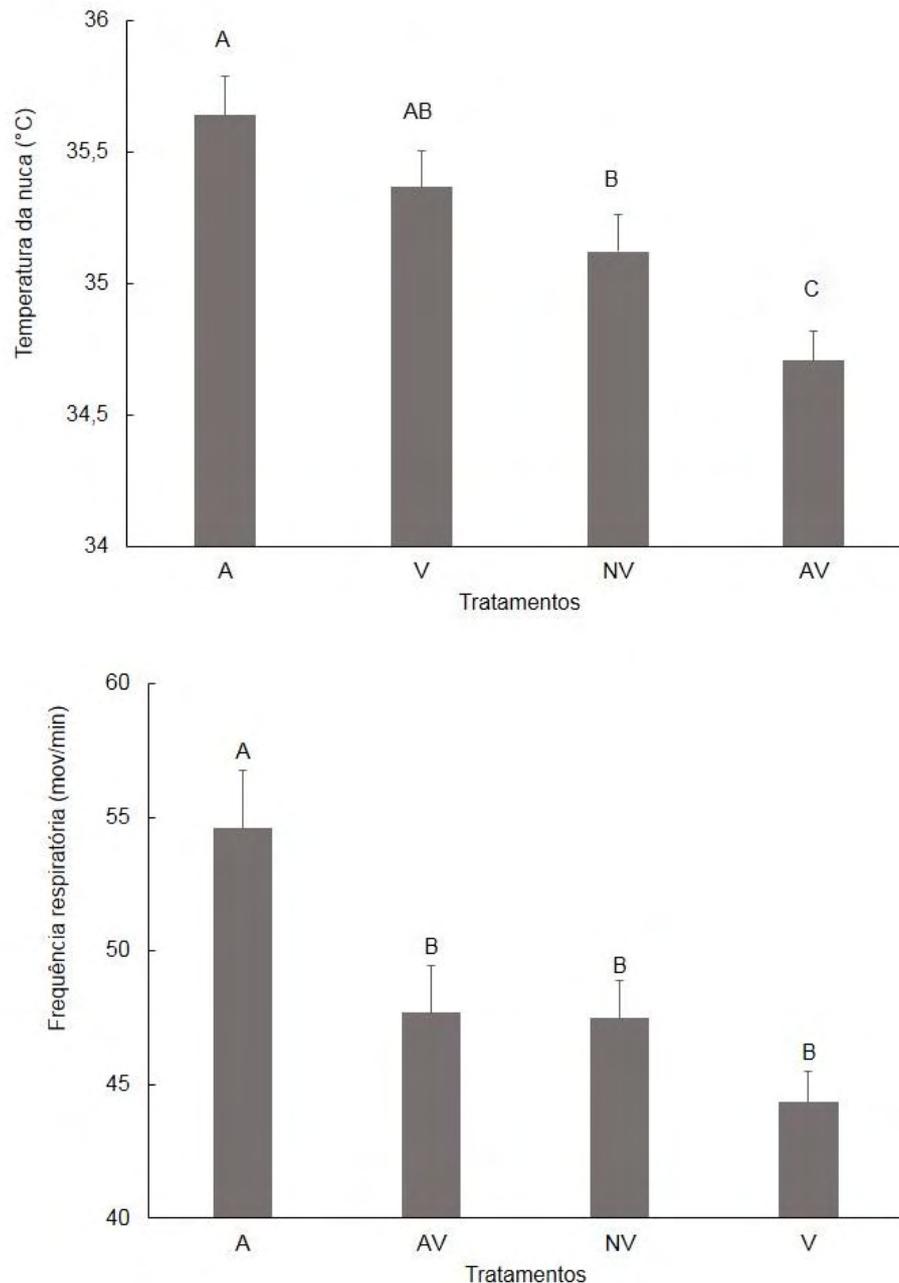
Fonte: Própria autoria

Como esperado, não houve diferença ($p < 0,05$) nas médias da temperatura do ar, umidade relativa do ar e no ITU. A temperatura máxima diária foi registrada às 14:00 em todos os tratamentos mantendo-se na faixa de 28,0 a 28,2 °C, considerado acima do limite crítico para suínos em fase de terminação. Destaca-se que as temperaturas médias do ar se mantiveram abaixo de 24 graus Celsius em todos os tratamentos não sendo observadas diferenças entre eles.

6.2.2 Análises fisiológicas

Foi observado efeito ($p < 0,01$) de tratamento sobre a termografia de infravermelho na região da nuca ($^{\circ}\text{C}$) e também sobre a frequência respiratória dos suínos durante período experimental. (Figura 14).

Figura 14 – Médias das imagens de termografia de infravermelho ($^{\circ}\text{C}$) da região da nuca e das frequências respiratórias (movimentos/minuto) dos animais em cada um dos tratamentos: Aspersão (A), Apersão e Ventilação (AV), Ventilação (V) e Nebulização e Ventilação (NV)



Fonte: Própria autoria.

Para a temperatura da nuca, as temperaturas dos animais do tratamento A ($35,6^{\circ}\text{C}$) e V ($35,3^{\circ}\text{C}$) não diferiram entre si. No entanto, os animais do tratamento A apresentaram

temperatura mais elevada ($p < 0.01$) comparada aos animais de NV e AV. As temperaturas dos animais do tratamento V e NV ($35,1^{\circ}\text{C}$) foram semelhantes. Os animais do tratamento AV ($34,7^{\circ}\text{C}$) apresentaram menor ($p < 0.01$) temperatura de superfície corporal comparado aos demais.

A temperatura da nuca de suínos tem sido estudada como uma área promissora para diagnóstico de condição de estresse por calor em suínos (CARVALHO; OLIVEIRA; TURCO, 2004; KIEFER et al., 2009; MANNO et al., 2006). Mano et al. (2006) observaram temperatura da nuca de $36,5^{\circ}\text{C}$ em suínos em crescimento e em ambiente de conforto ($22,8^{\circ}\text{C}$). Kiefer et al. (2010) também observaram suínos em terminação mantidos em ambiente de conforto (21°C) e encontraram temperatura da nuca de $36,2^{\circ}\text{C}$. No entanto, não há concordância entre os limites considerados de estresse para essa característica, uma vez que a temperatura de superfície corporal é sensível a diversos fatores ambientais e inerentes ao próprio animal, como densidade animal, condição de umidade dentro da instalação, raça, idade, entre outras. No estudo de Carvalho, Oliveira e Turco (2004), por exemplo, foi observada temperatura corporal de $31,04^{\circ}\text{C}$ para suínos em ambiente de conforto (22°C), ou seja, abaixo daquelas obtidas no presente estudo e nos demais estudos citados acima. Embora não se tenha um valor consolidado sobre a temperatura de superfície limite para que seja considerada condição de conforto em suínos, é bem estabelecido o fato de que a temperatura de superfície é parte importante dos mecanismos de ajustes fisiológicos e é importante que seja avaliada em conjunto com outras respostas fisiológicas a fim de se estabelecer condição de estresse nos animais.

Ao avaliar a frequência respiratória dos animais, observou-se que os animais do tratamento A ($54,6$ movimentos por minuto - mov/m), assim como ocorrido para a temperatura de superfície, também apresentaram maior valor ($p < 0,01$) para essa característica, comparada aos demais tratamentos. A frequência respiratória dos animais de AV ($47,7$ mov/m), NV ($47,5$ mov/m) e V ($44,3$ mov/m) não diferiram entre si.

As respostas dos animais por meio da temperatura de superfície da pele e da frequência respiratória podem indicar presença algum efeito de estresse nos animais do tratamento com Aspensor, uma vez que foram observadas respostas fisiológicas mais expressivas nesse tratamento comparado aos demais. Embora a temperatura do ar média observada no tratamento A, de $23,7^{\circ}\text{C}$, não seja considerada como ambiente em situação de estresse para suínos em crescimento, observou-se que a umidade relativa média esteve elevada, com valor de $81,7\%$. A umidade relativa do ar tem grande relevância sobre os mecanismos de dissipação de calor por via evaporativa, podendo facilitar ou complicar a homeostase. Para suínos, a umidade do ambiente ideal não deve ultrapassar 70%

(SAMPAIO, 2004; SARTOR et al., 2003; SILVA, 1999). A umidade relativa elevada também foi observada nos demais tratamentos, porém o tratamento A era o único que não apresentava o recurso de ventilação e isso pode ter influenciado de modo negativo o ajuste fisiológico dos animais desse tratamento, mantendo a frequência respiratória e temperatura de superfície corporal dos animais mais elevadas em relação aos demais tratamentos.

De modo geral, a frequência respiratória dos animais do tratamento A (54,6 mov/min), mesmo sendo o tratamento mais elevado, esteve pouco abaixo do limite considerado como conforto para suínos (< 60 mov/min) para essa categoria (OLIVEIRA et al., 2020; PANDORFI et al., 2007). Outros estudos como de Kiefer et al. (2010) encontraram frequência respiratória de 41,07 mov/min para suínos em terminação mantidos em ambiente com 21°C enquanto para ambiente de 32 °C observaram frequência respiratória de 93,46 mov.min. Já, Manno et al. (2006) observaram frequência respiratória de 48 mov.min em suínos entre 30 a 60 kg mantidos em conforto térmico ($22,8 \pm 1,30$ °C e $79,2 \pm 5,60\%$ UR) e 97 ± 16 movimentos por minuto para àqueles mantidos em desconforto térmico ($31,7 \pm 0,81$ °C e $65,9 \pm 6,30\%$). Dessa forma, no presente estudo considera-se que a frequência de 54,6 mov.min esteve próxima do limite crítico para considerar suínos em estresse térmico. Além disso, os resultados de temperatura de superfície corporal reforçam esses resultados, uma vez que para o tratamento A também foi observada a temperatura de superfície corporal mais elevada em relação aos animais dos demais tratamentos, sugerindo que a elevação de uma pode estar associada à elevação da outra.

6.2.3 Análise comportamental

Conforme mencionado no item 5.3, a avaliação do comportamento considerou 28 dias de monitoramento, sendo contabilizados os comportamentos posturais e ingestivos do animais durante um período de 10 horas/dia ao longo dos 28 dias (Tabela 10). Essa avaliação foi realizada utilizando a ferramenta computacional *frequency counter*. O comportamento foi avaliado usando a frequência (%) e o tempo (minutos) dispendidos pelo animal em cada comportamento e em cada um dos tratamentos durante o período de 10 horas de avaliação.

Tabela 10 – Análise descritiva dos dados de comportamento diário para os tratamentos Apersão (A), Apersão e Ventilação (AV), Nebulização e Ventilação (NV) e Ventilação (V)

Comportamento	Tratamento	Tempo de Observações (minutos e %)					
		Total (min)	Mín (min)	Max (min)	Total %	Min (%)	Max (%)
Andando	A	41,6	11,0	84,0	7,1	1,8	14,0
	AV	42,1	13,7	103,7	7,1	2,2	17,3
	NV	55,7	9,8	120,1	9,4	3,2	20,0
	V	37,4	11,3	76,7	6,3	1,8	12,7
Bebendo	A	15,1	3,2	90,6	2,5	0,5	15,1
	AV	10,6	3,5	67,2	1,7	0,6	11,2
	NV	13	0,6	59,7	2,1	0,2	9,9
	V	10,4	1,4	21,4	1,7	0,4	3,5
Comendo	A	80,6	17,8	182,4	13,5	2,9	30,4
	AV	76,6	17,8	131,6	12,8	4,2	21,9
	NV	65,7	25,4	113,0	11,2	4,2	18,8
	V	67,0	23,3	121,1	11,3	6,4	20,1
Deitado	A	448,2	273,0	530,0	75,7	54,3	88,3
	AV	455,6	283,3	532,3	76,8	53,0	88,7
	NV	444,5	201,58	538,9	76,0	62,3	89,8
	V	471,2	263,0	535,0	79,7	68,1	87,2
Manejo	A	5,4	2,6	15,2	0,9	0,4	3,9
	AV	7,1	2,1	53,8	1,3	0,3	12,8
	NV	5,7	2,0	28,2	0,9	0,3	4,7
	V	4,9	0,1	10,5	0,8	0,0	1,7

Fonte: Própria autoria.

Ao observar os dados descritivos para os comportamentos ao longo do dia, observou-se que os animais passaram a maior parte do seu dia deitado, entre 75,7 e 79,7 %, seguido pelo comportamento comendo, entre 11,2 a 13,5 %, andando, entre 9,5 a 6,4% e por fim bebendo entre 1,7 a 2,6 %.

De fato, estudos anteriores indicaram que os suínos passam a maior parte do tempo descansando e dormindo, conforme observado no presente estudo. Fraser (1984) observou que os suínos passam cerca de 19 horas por dia em descanso e dormindo, com a maior parte do sono verdadeiro ocorrendo durante a noite. Blackshaw (1981) observou que leitões jovens passaram 55-60% do seu tempo deitados, durante o período de 24 horas. Morrison et al. (2007) observaram que os suínos com 22 semanas de idade alojados em sistema convencional passaram 65% do tempo deitados.

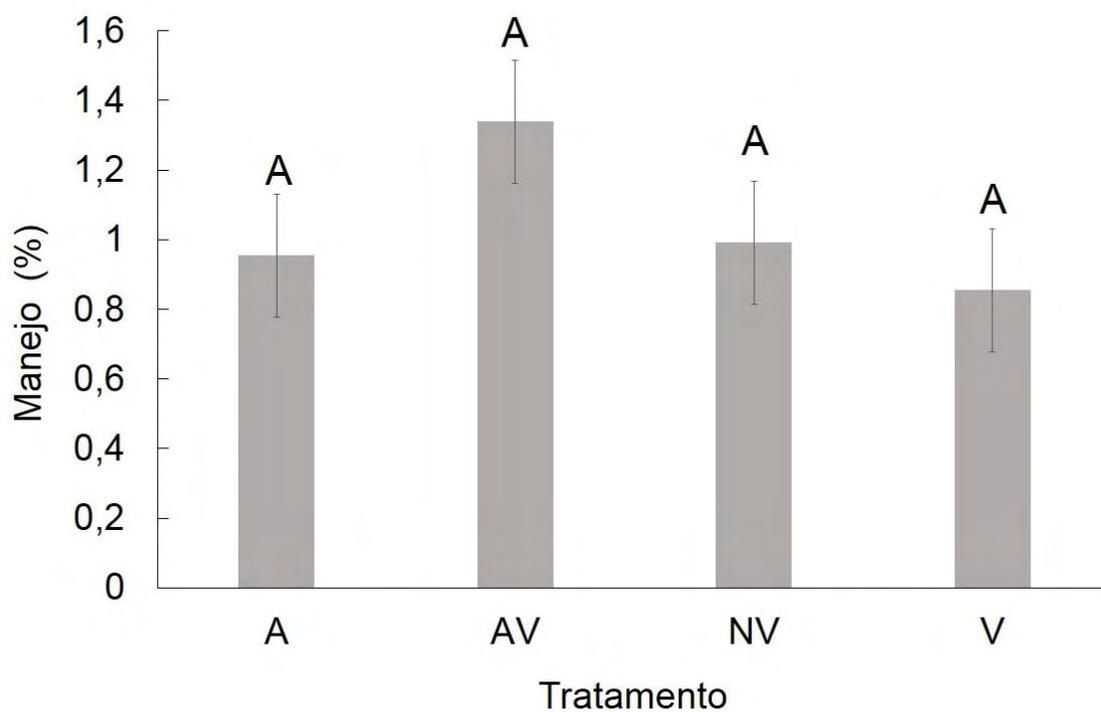
No presente estudo o comportamento de comer foi o segunda atividade de maior expressão (entre 11,2 a 13,5 %) e está de acordo com estudos prévios (DEBRECÉNI et al., 2014; HÖTZEL et al., 2009) que também observaram que esta é a segunda atividade de maior expressão dos suínos em crescimento. Debrecéni et al. (2014) observaram que os suínos realizaram essa atividade durante 14,5% do período diurno. Outros estudos também observaram o comportamento de comer em suínos e observaram uma ocorrência de padrão diurno, com ingestão modesta durante horas sem luz (FERRREIRA et al., 2016; FRASER, 1984; HYUN et al., 1997).

Muitos dos estudos sobre comportamento têm sido realizados para identificar o padrão de comportamento sobre o uso do espaço (GONYOU et al., 2006; SPOOLDER et al., 2012), sobre o padrão de alimentação (HYUN et al., 1997), sobre o nível de atividade ou agressividade (CHEN et al., 2019; VIAZZI et al., 2014) e tem testado isso em relação à ambientes com diferentes temperaturas do ar, enriquecimento ambiental, tipo de cama, comedouros, entre outros. Todos esses estudos são de grande importância para se obter conhecimentos sobre o comportamento animal, uma vez que conhecendo o padrão esperado para cada tipo de ambiente e categoria animal é possível inferir o estado de bem-estar desses animais por meio do monitoramento de possíveis desvios de comportamento.

Ressalta-se que um dos fatores que mais afetam o bem-estar dos suínos em sistemas intensivos está relacionado com o ambiente no qual os animais são mantidos e nesse aspecto, a temperatura do ar é um dos fatores que tem efeitos diretos sobre o comportamento dos suínos (NASIRAHMADI et al., 2015). Os modernos sistemas de produção de suínos têm cada vez mais lançado mão da utilização dos recursos climáticos para aliviar os prejuízos causados aos animais com as elevadas temperaturas do ar dentro das instalações, e investigar o padrão do comportamento dos suínos frente a esses recursos climáticos pode contribuir com avanços sobre melhores estratégias de manejo visando melhorias no bem-estar e produtividade animal.

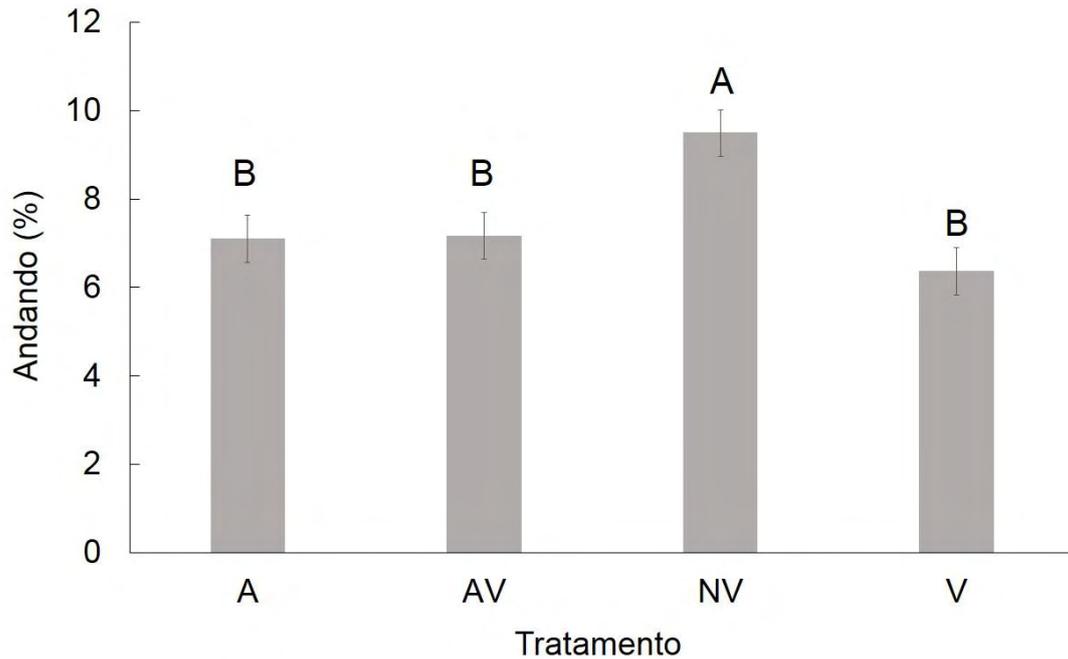
No presente estudo observou-se efeito dos tratamentos ($p < 0,01$) para todos os comportamentos avaliados. O comportamento identificado como “manejo” não é representativo de nenhuma atividade animal, se tratando do período diário no qual o animal era manejado para a coleta dos dados fisiológicos ou limpeza das baias, conforme mencionado no item material e métodos. Esse período foi computado no presente estudo e ficou demonstrado que o tempo dispendido nessa situação foi semelhante em todos os tratamentos (Figura 15), indicando que essa atividade de manejo não teve interferência sobre os resultados.

Figura 15 – Médias da frequência (%) do comportamento Manejo para os tratamentos Ventilação (V), Aspersão (A), Aspersão e Ventilação (AV) e Nebulização e Ventilação (NV)



Fonte: Própria autoria.

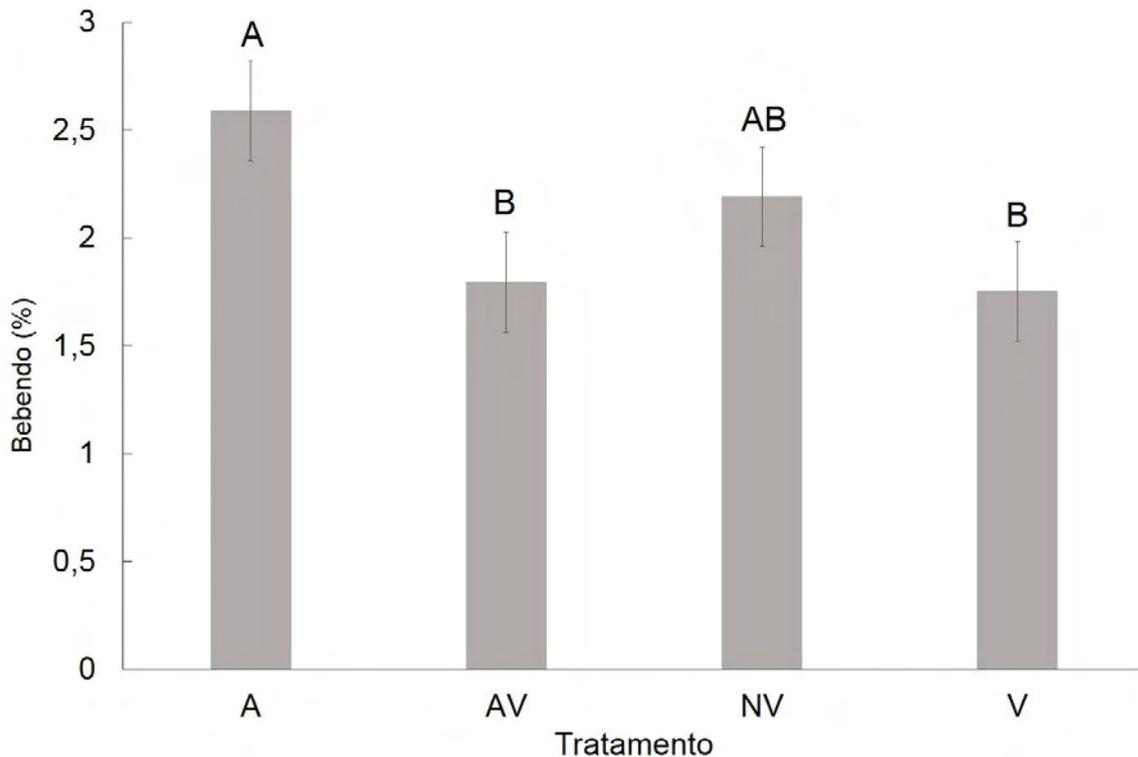
Figura 16 – Médias da frequência (%) do comportamento Andando para os tratamentos Ventilação (V), Aspersão (A), Aspersão e Ventilação (AV) e Nebulização e Ventilação (NV)



Fonte: Própria autoria.

Observou-se efeito de tratamento ($p < 0,01$) para o comportamento andando (Figura 16), com uma maior frequência (9,4%) no tratamento NV quando comparado aos tratamentos A (7,1 %), AV (7,1%) e V (6,3%). Os tratamentos A, AV e V foram semelhantes entre si. Segundo Ferreira et al. (2016), o comportamento de andar e explorar o ambiente é uma característica comportamental natural da espécie e esses autores observaram frequência desse comportamento de 10,1% próximo ao observado no tratamento NV. Interessante destacar que no presente estudo todos os tratamentos mantiveram ambiente térmico semelhante, com temperatura do ar entre 23,5 °C à 23,7 °C e, portanto, a diferença observada entre os tratamentos não pode ser atribuída a uma variação da temperatura do ambiente e pode estar relacionado como sistema de resfriamento imposto aos animais. O comportamento andando indica uma maior atividade do animal e estudos prévios relacionam maior atividade animal com elevação do gasto energético e conseqüentemente com um menor ganho de peso corporal (BEZERRA et al., 2019).

Figura 17 – Médias da frequência (%) do comportamento Bebendo para os tratamentos Ventilação (V), Aspersão (A), Aspersão e Ventilação (AV) e Nebulização e Ventilação (NV)

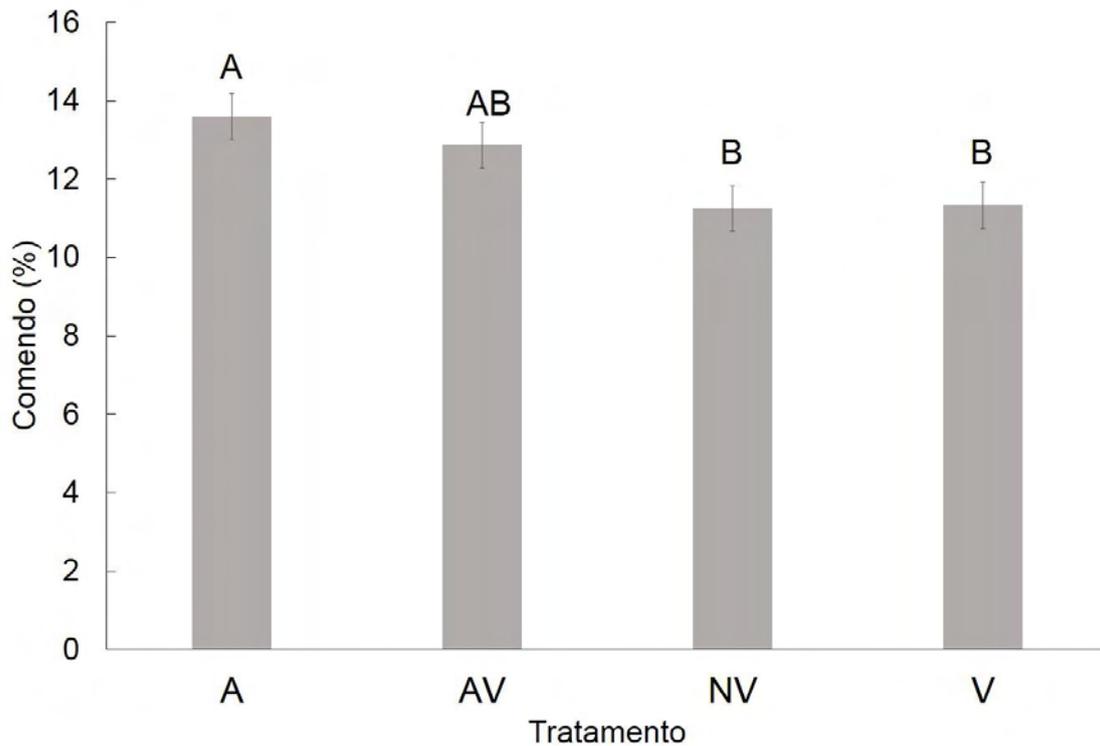


Fonte: Própria autoria.

Também foi observado efeito de tratamento ($p < 0,01$) para o comportamento bebendo (Figura 17), sendo o tratamento A (2,5%) com maior frequência e semelhante ao tratamento NV (2,1%). Porém, NV, V (1,7%) e AV (1,7%) não diferiram entre si. A avaliação dos dados fisiológicos indicaram que a frequência respiratória dos animais do tratamento A foi a mais elevada (54,6 mov/min) comparado aos animais dos demais tratamentos. Esse valor é próximo do limite considerado como estresse para animais (60 mov/min) e pode ter influenciado o maior consumo de água nesse tratamento, uma vez que o maior consumo de água é uma das estratégias para reduzir o calor corporal interno dos animais domésticos (OLIVEIRA et al., 2020). Considerando todos os tratamentos, os animais dispenderam aproximadamente entre 10 à 15 min nesse comportamento (2,5 a 1,7 %) sendo um pouco acima daquele observado por Ferreira et al. (2016), que relataram um tempo de 10 min (observado em 24 horas) no comportamento de beber de suínos em terminação. Já, Andersen et al. (2014) observaram que suínos dispenderam em média 8,5 min bebendo água (20 horas de observação). Poucos estudos avaliam especificamente o comportamento ingestivo de água de suínos como os do presente estudo ou o de Ferreira et al. (2016) e Andersen et al. (2014), sendo que grande parte dos trabalhos avaliam em conjunto os comportamentos ingestivos de água e ração (BEZERRA et al., 2019; PARREIRA et al., 2021). De modo geral, no presente estudo, observou-se padrões de

comportamento ingestivo de água um pouco acima dos observados em estudos prévios, mesmo considerando que os ambientes dos 4 tratamentos permaneceram em situação de temperatura do ar considerada como de conforto.

Figura 18 – Médias da frequência (%) do comportamento Comendo para os tratamentos Ventilação (V), Aspersão (A), Aspersão e Ventilação (AV) e Nebulização e Ventilação (NV)



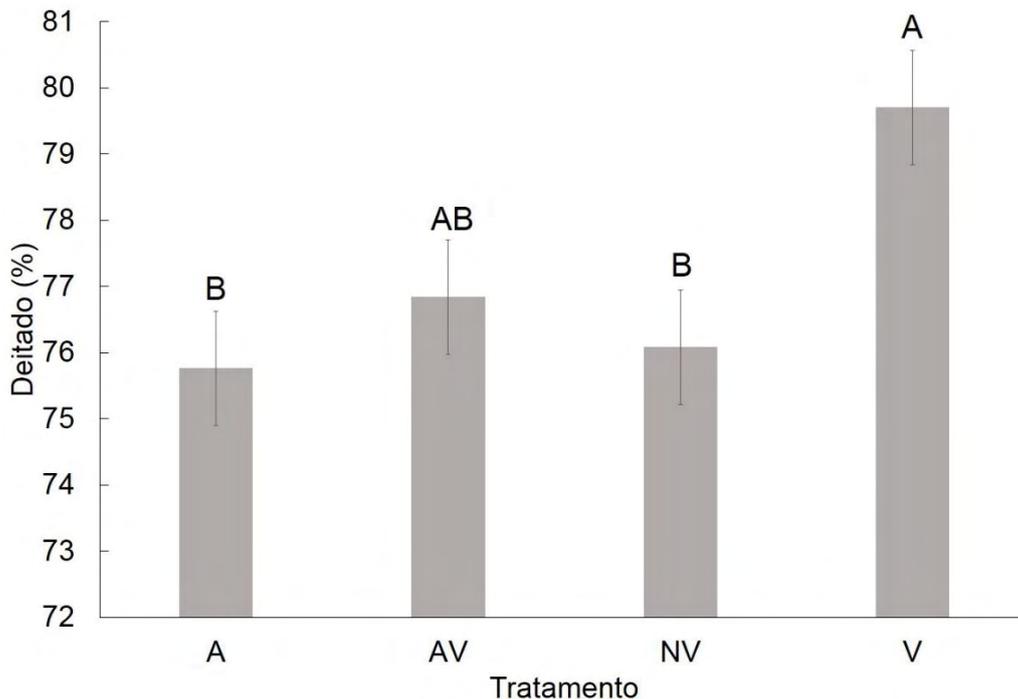
Fonte: Própria autoria.

Para o comportamento comendo (Figura 18) observou-se que os animais do tratamento A (13,5%) dispenderam mais tempo ($p < 0,01$) nesse comportamento comparado aos demais, com exceção do tratamento AV (12,8%), o qual foi semelhante ao A. O comportamento nos tratamentos AV, V (11,3%) e NV (11,2%) não diferiram entre si. No presente estudo, considerando que os comportamentos foram observados durante 10 horas diárias, pode-se inferir que os animais do tratamento A permaneceram 1 h 20 m comendo (13,5 % de 10 horas) enquanto os animais dos tratamentos AV, V e NV dispenderam entre 1 h 16 m à 1 h 05 m. Estimar o tempo que o animal permanece no cocho comendo, além de outras características como o tamanho das refeições (comportamento não avaliado no presente estudo), tem relação positiva com a deposição de gordura e proteína, o que é desejável para suínos em engorda (DE HAER; MERKS, 1992). Porém, diversos aspectos podem influenciar no comportamento do consumo de ração dos suínos e diferenças entre estudos provavelmente também refletem diferenças nas condições

usadas em termos de genótipos, sexo, faixas de peso vivo, tipo das baias, densidade animal, sistemas de alimentação (individual, em grupo), métodos de avaliação (eletrônico ou visual), além das condições ambientais. Hyun et al. (1997) avaliaram os suínos por 24 horas e observaram tempo de ocupação do cocho pelos animais semelhante ao do presente estudo, sendo que os animais permaneceram comendo durante 1 h 18 m (78,1 m^d). Já Ferreira et al. (2016) observaram que suínos em crescimento (durante 24 horas) permaneceram 2 h 06 m comendo e indicaram que esse comportamento foi realizado predominantemente no período do dia.

No presente estudo, o fato dos animais do tratamento A apresentarem maior frequência respiratória (Figura 18) em relação aos demais, assim como a temperatura superfície corporal, não afetou negativamente o tempo de consumo, uma vez que esses animais dispenderam maior tempo comendo, juntamente com os animais do tratamento AV. Uma das explicações para isso pode estar relacionada com o baixo nível de estresse, indicado pela frequência respiratória pouco abaixo do limite considerado crítico para suínos, o que pode não ter sido suficiente para afetar o consumo desses animais. Outra explicação é que, conforme visto, o fato dos animais desse tratamento (A) terem consumido mais água pode ter contribuído para possíveis ajustes fisiológicos na redução do estresse térmico, também não afetando o consumo.

Figura 19 – Médias da frequência (%) do comportamento Deitado para os tratamentos Ventilação (V), Aspersão (A), Aspersão e Ventilação (AV) e Nebulização e Ventilação (NV)



Fonte: Própria autoria.

Observou-se efeito de tratamento ($p < 0,01$) para o comportamento deitado (Figura 19), sendo que os animais do tratamento V (79,7%) dispenderam mais tempo ($p < 0,01$) nesse comportamento do que NV (76,0%) e A (75,7%) porém não diferiu do animais do tratamento AV (76,8%). Animais de AV, NV e A não diferiram entre si. Alguns estudos relatam que o tempo de permanência do animal deitado tem correlação positiva com o ganho de peso, uma vez que esse comportamento promove conservação da energia bem como a reparação dos níveis normais das atividades neuronais dos suínos (BROOM; FRASER 2010). Por outro lado, de acordo com Medeiros et al. (2014), o fato de os suínos em terminação permanecerem grande parte do dia dormindo ou deitados pode ser explicado pelo maior peso do animal e a dificuldade de se locomover na baia, podendo ser um situação não muito favorável às questões de bom bem-estar. Outros estudos observaram que em situação de temperaturas do ar elevadas, os animais permanecem mais tempo deitados do que na posição em pé, sendo que um longo tempo de permanência na posição deitado poderia ser indicativo de que o animal esteja sendo acometido de estresse por calor. Dessa forma, não há uma consonância entre os estudos que indiquem que o fato do animal passar mais tempo deitado seja resultado de um estado de pobre ou bom bem-estar. Alguns estudos que avaliaram bem-estar de suínos em baias com enriquecimento ambiental, observaram que os suínos da baia com enriquecimento ficaram mais ativos, com uma maior movimentação na instalação (PARREIRA et al., 2021) e maior

atividade exploratória (MELOTTI et al., 2011). Ambos os estudos caracterizaram esse padrão de comportamento como sendo de maior bem-estar para os animais. Em outro estudo, Bezerra et al. (2019) avaliaram o efeito do enriquecimento ambiental sobre o desempenho e comportamento de leitões e observaram que o comportamento deitado foi o de maior expressão e apresentou variação entre os tratamentos. Os autores concluíram que o enriquecimento ambiental melhora os comportamentos dos leitões, porém pode provocar alterações fisiológicas que podem comprometer o desempenho. Dessa forma, conhecer o padrão desse comportamento frente aos diferentes ambientes e estruturas de instalações é de grande importância para se estabelecer estratégias efetivas para melhorar o bem-estar em animais confinados e ao mesmo tempo obter boa produtividade animal, sobretudo ao considerar que o período de sono e descanso é crucial para alcançar bons níveis de produtividade e também de bem-estar dos suínos.

No presente estudo, durante as 10 horas de observação, os animais permaneceram entre 75,7% (A) e 79,7 % (V) na posição deitado, sendo este resultado semelhante ao observado por Kiefer et al. (2009) (76,6%) que também avaliaram o comportamento de suínos ao longo do dia. No entanto, é intrigante observar que no estudo de Kiefer et al. (2009) os suínos estavam submetidos a condição de estresse por calor (temperatura do ar de 31 ° C), enquanto no presente estudo, no tratamento A, a temperatura do ar era considerada como conforto (23,7 °C). Isso sugere que é bastante complexo inferir uma condição de estresse em animais apenas por meio da expressão de seu comportamento, sendo importante envolver outros fatores e características, seja do animal ou ambiente, para se ter um diagnóstico preciso sobre sua condição.

7 CONCLUSÃO

O presente estudo subsidiou e contribuiu com os primeiros passos para o desenvolvimento de um modelo computacional baseado em rede neural convolucional para classificação automática do comportamento de suínos utilizando um banco de vídeo-imagens. Foram desenvolvidos dois modelos utilizando banco de imagens balanceados e não balanceados, sendo a maior acurácia obtida com o banco balanceado.

Os diferentes sistemas de resfriamentos adotados no presente estudo parecem ter interferido na dinâmica dos padrões comportamentais observados. O tratamento utilizando apenas o recurso de aspersão (A) foi promissor em relação aos comportamentos de beber e comer, sendo esse o tratamento no qual os animais mais executaram tais atividades. Já, os animais do tratamento com recurso de ventilação (V) foram os que passaram maior tempo deitados, ao mesmo tempo que apresentaram menor tempo em atividade (comportamento andando) e também menos tempo comendo.

Os tratamentos apresentaram efeito sobre as respostas de frequência respiratória e temperatura de superfície corporal, porém as variações dessas características não demonstraram de modo claro uma interferência na dinâmica dos comportamentos. Observou-se frequência respiratória mais elevada e próxima do limite considerado de estresse nos animais do tratamento A, porém isso não foi suficiente para interferir negativamente na dinâmica do comportamento de consumo de ração e água, que se mostrou mais elevados nesse tratamento.

8 REFERÊNCIAS

- ANDRADE, T. V.; ANDRADE, L. S.; FARIA, L. A.; SOUSA, P. H. A. A.; BORGES, L. S.; SANTOS, R. N. V.; LIMA, B. S. L.; BARROS JUNIOR, C. P.; CARVALHINHO, S. T. Comportamento de leitões na fase de creche submetidos ao enriquecimento ambiental. **Revista de Ciências Agroveterinárias**, Lages, v. 18, n. 3, p. 346-351, 23, 2019.
- BAÊTA, F. C.; MEADOR, N. F.; SHANKLIN, M. D. **Equivalent temperature index at temperatures above thermoneutral for lacting dairy cows**. St. Joseph: ASAE, Joseph, 1997.
- BERNARDINO, T.; TATEMOTO, P.; MORAES, J. E.; MORRONE, B.; ZANELLA, A. J. High fiber diet reduces stereotypic behavior of gilts but does not affect offspring performance. **Applied Animal Behaviour Science**, Amsterdam, v. 243, p. 105433, 2021.
- BEZERRA, B. M. O.; SILVA, S. S. C.; OLIVEIRA, A. M. A.; SILVA, C. V. O.; PARENTE, R. A.; ANDRADE, T. S.; EVANGELISTA, J. N. B.; PINHEIRO, D. C. S. N. Avaliação do estresse e do desempenho de suínos na fase de creche, empregando-se técnicas de enriquecimento ambiental. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**, Belo Horizonte, v. 71, n. 1, p. 281-290, 2019.
- BIRD, N.; CRABTREE, H. G.; SCHOFIELD, C. P. Engineering technologies enable real time information monitoring in pig production. **BSPA Occasional Publication**, Cambridge, v. 28, p. 105-112, 2001.
- BLACKSHAW, J. K. Some behavioural deviations in weaned domestic pigs: persistent inguinal nose thrusting, and tail and ear biting. **Animal Science**, Penicuik, v. 33, n. 3, p. 325-332, 1981.
- BOILEAU, A.; FARISH, M.; TURNER, S. P.; CAMERLINK, I. Infrared thermography of agonistic behaviour in pigs. **Physiology & Behavior**, Oxford, v. 210, art. 112637, 2019.
- BORTOLOZZO, F. P.; GAGGINI, T. S.; WENTZ, I. Infertilidade sazonal no suíno: Caracterização e consequências durante a fase gestacional. *In*: SIMPÓSIO INTERNACIONAL DE SUINOCULTURA. PRODUÇÃO, REPRODUÇÃO E SANIDADE SUÍNA, 6., Porto Alegre. **Anais [...]**. Porto Alegre, 2011. p. 117-131.
- BREWSTER, L. R.; DALE, J. J.; GUTTRIDGE, T. L.; GRUBER, S. H.; HANSELL, A. C.; ELLIOTT, M.; COWX, I. G.; WHITNEY, N. M.; GLEISS, A. C. Development and application of a machine learning algorithm for classification of elasmobranch behavior from accelerometry data. **Marine Biology**, [s.l.], v. 165, art. 62, 2018.
- BROOM, D. M. Indicators of poor welfare. **British Veterinary Journal**, London, v. 142, p. 524-526, 1986.
- BROOM, D. M. Animal welfare: concepts and measurement. **Journal of Animal Science**, Champaign, v. 69, p. 4167-4175, 1991.
- BROOM, D. M.; FRASER, A. F. **Comportamento e bem-estar de animais domésticos**. 4. ed. Barueri: Manole, 2010. 438 p.

BROWN, D. D. *et al.* Observing the unwatchable through acceleration logging of animal behavior. **Animal Biotelemetry**, London, v. 1, art. 20, 2013.

BROWN-BRANDL, T. M.; NIENABER, J. A.; XIN, H.; GATES, R. S. A literature review of swine heat production. **Transaction of the ASABE**, St. Joseph, v. 47, n. 1, p. 259-270, 2013.

BUFFINGTON, D. E. *et al.* Black globe-humidity index (BGHI) as a comfort equation for dairy cows. **Transactions of the ASAE**, St. Joseph, v. 24, n. 3, p. 711-714, 1981.

BÜNGER, B.; SCHRADER, L.; SCHRADER, H.; ZACHARIAS, B. Agonistic behaviour, skin lesions and activity pattern of entire male, female and castrated male finishing pigs. **Applied Animal Behaviour Science**, Amsterdam, v. 171, p. 64-68, 2015.

CARVALHO, C. M. C. *et al.* Bem-estar na suinocultura. **Nutritime**, Viçosa, v.11, n. 2, p. 2272-2286, 2013.

CARVALHO, L. E.; OLIVEIRA, S. M. P.; TURCO, S. H. N. A utilização da nebulização e ventilação forçada sobre o desempenho e a temperatura de pele de suínos na fase de terminação. **Revista Brasileira de Zootecnia**, Viçosa, v. 33, n. 6, p. 1486-1491, 2004.

CHEN, C.; ZHU, W.; LIU, D.; STEIBEL, J.; SIEGFORD, J.; WURTZ, K.; HAN, J.; NORTON, T. Detection of aggressive behaviours in pigs using a RealSence depth sensor. **Computers and Electronics in Agriculture**, Amsterdam, v. 166, art. 105003, 2019.

CHEN, C.; ZHU, W.; STEIBEL, J.; SIEGFORD, J.; HAN, J.; NORTON, T. Classification of drinking and drinker-playing in pigs by a video-based deep learning method. **Biosystems Engineering**, Heidelberg, v. 196, p. 1-14, 2020a.

CHEN, C.; ZHU, W.; STEIBEL, J.; SIEGFORD, J.; HAN, J.; NORTON, T. 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**, Amsterdam, v. 176, p. 105642, 2020b.

CONDOTTA, I. C. F. S.; BROWN-BRANDL, T. M.; SILVA-MIRANDA, K. O.; STINN, J. P. Evaluation of a depth sensor for mass estimation of growing and finishing pigs. **Biosystems Engineering**, Heidelberg, v. 173, p. 11-18, 2018.

COOK, N. J.; CHABOT, B.; LUI, T.; BENCH, C. J.; SCHAEFER, A. L. Infrared thermography detects febrile and behavioural responses to vaccination of weaned piglets. **Animal**, Cambridge, v. 9, n. 2, p. 339-346, 2015.

DEBRECENI, O.; LEHOTAYOVÁ, A.; BUČKO, O.; PETRÁK, J. The Behaviour of the Pigs Housed in Hot Climatic Conditions. **Journal of Central European Agriculture**, [s.l.], v. 15, n. 1, p. 64-75, 2014.

DE HAER, L. C. M.; MERKS, J. W. M. Patterns of daily food intake in growing pigs. **Animal Production**, Cambridge, v. 54, art. 95, 1992.

DELA RICCI, G. *et al.* Climatização específica de maternidade suína: avaliação etológica de fêmeas lactantes. **Revista Brasileira de Higiene e Sanidade Animal**, Fortaleza, v. 12, n. 2, p. 198-204, 30 2018a.

DELA RICCI, G. *et al.* Interesse comportamental de machos suínos por diferentes tipos de enriquecimentos ambientais. **Medicina Veterinária (UFRPE)**, Recife, v. 12, n. 3, p. 241-247, 2018b.

DELA RICCI, G.; SILVA-MIRANDA, K. O.; TITTO, C. G. Infrared thermography as a non-invasive method for the evaluation of heat stress in pigs kept in pens free of cages in the maternity. **Computers and Electronics in Agriculture**, Cambridge, v. 157, p. 403-409, 2019.

FARM ANIMAL WELFARE COUNCIL – FAWC. Updates the five freedoms. **Veterinary Record**, Apartado, v. 17, art. 357, 1992.

FERNANDES, J. G. L. *et al.* Inteligência artificial: uma visão geral. **Revista Eletrônica Engenharia Estudos e Debates**, 2018.

FERREIRA, R. A. **Maior produção com melhor ambiente**: para aves, suínos e bovinos. 2. ed. Viçosa, MG: Aprenda Fácil, 2011.

FERREIRA, R. A.; FASSANI, É. J.; ROCHA, L. F.; OLIVEIRA, R. F.; RIBEIRO, B. P. V. B.; ABREU, M. L. T.; CANTARELLI, V. S. Desempenho e comportamento de suínos em fase de terminação submetidos a diferentes programas de luz. **Revista Brasileira de Saúde e Produção Animal**, v. 17, n. 2, p. 272-279, 2016.

FONOLLA, R. *et al.* Multi-modal classification of polyp malignancy using cnn features with balanced class augmentation. *In*: INTERNATIONAL SYMPOSIUM ON BIOMEDICAL IMAGING, 16., 2019, Venice. **Anais** [...]. Venice: IEEE, 2019. p. 74-78.

FONTANA, I. *et al.* An innovative approach to predict the growth in intensive poultry farming. **Computers and Electronics in Agriculture**, Amsterdam, v. 119, p. 178-183, 2015.

FOPPA, L. *et al.* Enriquecimento ambiental e comportamento de suínos: revisão. **Brazilian Journal of Biosystems Engineering**, Tupã, v. 8, n. 1, p. 1-7, 2014.

FRASER, D. The role of behavior in swine production: a review of research. **Applied Animal Ethology**, v. 11, n. 4, p. 317-339, 1984.

GONYOU, H. W. *et al.* Application of broken-line analysis to assess floor space requirements of nursery and grower-finisher pigs expresses on an allometric basis. **Journal Animal Science**, v. 84, p. 229-235, 2006.

GROOT, J. *et al.* Long-term effects of social stress on antiviral immunity in pigs. **Physiology and Behavior**, v. 73, p. 145-158, 2001.

GUARINO, M. *et al.* A blueprint for developing and applying precision livestock farming tools: A key output of the EU-PLF project. **Animal Frontiers**, [London], v. 7, p. 12-17, 2017.

- HANSEN, M. F. *et al.* Towards on-farm pig face recognition using convolutional neural networks. **Computers in Industry**, Amsterdam, v. 98, p. 145-152, 2018.
- HAER, L. C. M. de; MERKS, J. W. M. Patterns of daily food intake in growing pigs. **Animal Science**, Penicuik, v. 54, n. 1, p. 95-104, 1992.
- HÖTZEL, M. J.; MACHADO FILHO, L. C. P. Bem-estar animal na agricultura do século XXI. **Revista de Etologia**, São Paulo, v. 6, p. 3-15, 2004.
- HÖTZEL, M. J.; LOPES, E. J. C.; DE OLIVEIRA, P. A. V.; GUIDONI, A. L. Behaviour and performance of pigs finished on deep bedding with wood shavings or rice husks in summer. **Animal Welfare**, Herts, v. 18, p. 65-71, 2009.
- HUYNH, T. T. T. *et al.* Effects of increasing temperatures on physiological changes in pigs at different relative humidities. **Journal of Animal Science**, Champaign, v. 83, p. 1385-1396, 2005.
- HUYN, T. T. T.; AARNINK, A. J. A.; GERRITS, W. J. J.; HEETKAMP, M. J. H.; CANH, T. T.; SPOOLDER, H. A. M.; KEMP, B.; VERSTEGEN, M. W. A. Thermal behaviour of growing pigs in response to high temperature and humidity. **Applied Animal Behaviour Science**, Amsterdam, v. 91, n. 1-2, p. 1-16, 2005.
- HYUN, Y.; ELLIS, M.; MCKEITH, F. K.; WILSON, E. R. Feed intake Pattern of group-housed growing-finishing pigs monitored using a computerized feed intake recording system. **Journal Animal Science**, Champaign, v. 75, p. 1443-1451, 1997
- JONES, E. K. M.; WATHES, C. M.; WEBSTER, A. J. F. Avoidance of atmospheric ammonia by domestic fowl and the effect of early experience. **Applied Animal Behaviour Science**, Amsterdam, v. 90, p. 293-308, 2010.
- KAMMERSGAARD, T. S.; MALMKVIST, J.; PEDERSEN, L. J. Infrared thermography – a non-invasive tool to evaluate thermal status of neonatal pigs based on surface temperature. **Animal**, Cambridge, v. 7, n. 12, p. 2026-2034, 2013.
- KAMILARIS, A.; KARTAKOULLIS, A. PRENAFETA-BOLDÚ, F.X. A review on the practice of big data analysis in agriculture. **Computers and Electronics in Agriculture**, Cambridge, v. 143, p. 23-27, 2017.
- KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. Deep learning in agriculture: a survey. **Computers and Electronics in Agriculture**, Cambridge, v. 147, p. 70-90, 2018.
- KARPATY, A. **Convolutional neural networks for visual recognition**. 2017. Disponível em: <http://cs231n.github.io/convolutional-networks/>. Acesso em: 10 nov. 2021.
- KASHIHA, M. *et al.* Automatic identification of marked pigs in a pen using image pattern recognition. **Computers and Electronics in Agriculture**, Cambridge, v. 93, p. 111-120, 2013.
- KASHIHA, M. A.; BAHR, C.; OTT, S.; MOONS, C. P. H.; NIEWOLD, T. A.; TUYTTENS, F.; BERCKMANS, D. Automatic monitoring of pig locomotion using image analysis. **Livestock Science**, Amsterdam, v. 159, p. 141-148, 2014.

- KIEFER, C. *et al.* Respostas de suínos em crescimento mantidos em diferentes temperaturas. **Archivos de Zootecnia**, Córdoba, v. 58, n. 221, p. 55-64, 2009.
- KIEFER, C. *et al.* Respostas de suínos em terminação mantidos em diferentes ambientes térmicos. **Revista Brasileira de Saúde e Produção Animal**, Salvador, v. 11, n. 2, p. 496-504, 2010.
- KNIZKOVA, I. *et al.* Applications of infrared thermography in animal production. **Journal of Agricultural Faculty, OMU**, [s.l.], v. 22, p. 329-336, 2007.
- KONGSRO, J. Estimation of pig weight using a Microsoft Kinect prototype imaging system. **Computers and Electronics In Agriculture**, Cambridge, v. 109, p. 32-35, 2014.
- KUMAR, S. *et al.* Deep learning framework for recognition of cattle using muzzle point image pattern. **Measurement**, London, v. 116, p. 1-17, 2018.
- KVAM, J.; KONGSRO, J. In vivo prediction of intramuscular fat using ultrasound and deep learning. **Computers and Electronics in Agriculture**, Cambridge, v. 142, p. 521-523, 2017.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, London, v. 521, n. 7553, p. 436-44, 2015.
- LUDTKE, C.; CALVO, A. V.; BUENO, A. D. **Produção de suínos: teoria e prática**. Brasília: Associação Brasileira dos Produtores de Suínos, 2014.
- MACHADO FILHO, L. C. P.; HÖTELZ, M. J. Bem-estar dos suínos. *In: SEMINÁRIO INTERNACIONAL DE SUINOCULTURA*, 5, 2000, São Paulo. **Anais [...]**. São Paulo, 2000. p. 1-13.
- MANGOLD, D. W.; HAZEN, T. E.; HAYS, V. W. Effect air temperature on performance of growing: finishing swine. **Transaction of the ASAE**, St. Joseph, v. 10, n. 3, p. 370-375, 1967.
- MANNO, M. C. *et al.* Efeitos da temperatura ambiente sobre o desempenho de suínos dos 30 aos 60 kg. **Revista Brasileira de Zootecnia**, Viçosa, v. 35, n. 2, p. 471-477, 2006.
- MARCAL, A.; CUNHA, M. Development of an image-based system to assess agricultural fertilizer spreader pattern, **Computers and Electronics in Agriculture**, Cambridge, v. 162, p. 380-388, 2019.
- MCGOVERN, R. R.; BRUCE, J. M. A model of the thermal balance for cattle in hot conditions. **Journal Agricultural Engineer Research**, [s.l.], v. 77, p. 81-92, 2000.
- MELOTTI, L.; OOSTINDJER, M.; BOLHUIS, J. E.; HELD, S.; MENDEL, M. Coping personality type and environmental enrichment affect aggression at weaning in pigs. **Applied Animal Behaviour Science**, Amsterdam, v. 133, n. 3-4, p. 144-153, 2011.
- MEUNIER-SALAÜN, M. C.; GUÉRIN, C.; BILLON, Y.; SELLIER, P.; NOBLET, J.; GILBERT, H. Divergent selection for residual feed intake in group-housed growing pigs: characteristics of physical and behavioural activity according to line and sex. **Animal**, Cambridge, v. 8, n. 11, p. 1898-1906, 2014.

MISIMI, E.; OYE, E. R.; STURE, O.; MATHIASSEN, J. R. Robust classification approach for segmentation of blood defects in cod fillets based on deep convolutional neural networks and support vector machines and calculation of gripper vectors for robotic processing. **Computers and Electronics in Agriculture**, Cambridge v. 139, p.138-152, 2017.

MORRONE, B.; BERNARDINO, T.; TATEMOTO, P.; RODRIGUES, F. A. M. L.; MORAES, J. E.; CRUZ, T. D. A.; ZANELLA, A. J. Indication that the presence of older conspecifics reduces agonistic behaviour in piglets at weaning. **Applied Animal Behaviour Science**, Amsterdam, v. 234, p. 105201, 2021.

NÄÄS, I. A. **Novas perspectivas da ambiência em relação ao bem-estar dos suínos e do trabalhador**. 2007. Disponível em: www.porkworld.com.br/index.php?documento=111#. Acesso em: 09 dez. 2019.

NANNONI, E.; SARDI, L.; VITALI, M.; TREVISI, E.; FERRARI, A.; BARONE, F.; BACCI, M. L.; BARBIERI, S.; MARTELLI, G. Effects of different enrichment devices on some welfare indicators of post-weaned undocked piglets. **Applied Animal Behaviour Science**, Amsterdam, v. 184, p. 25-34, 2016.

NASIRAHMADI, A.; RICHTER, U.; HENSEL, O.; EDWARDS, S.; STURM, B. Using machine vision for investigation of changes in pig group lying patterns. **Computers and Electronics in Agriculture**, Cambridge, v. 119, p. 184-190, 2015.

NATIONAL WEATHER SERVICE CENTRAL REGION - NWSCR. **Livestock hot weather stress: regional operations manual letter C-31-76**. Kansas City, MO: NWACR, 1976.

NI, Ji-Qin; LIU, S.; RADCLIFFE, J. S.; VONDEROHE, C. Evaluation and characterization of passive infrared detectors to monitor pig activities in an environmental research building. **Biosystems Engineering**, London, v. 158, p. 86-94, 2017.

NILSSON, M.; HERLIN, A. H.; ARDÖ, H.; GUZHVA, O.; ÅSTRÖM, K.; BERGSTEN, C. Development of automatic surveillance of animal behaviour and welfare using image analysis and machine learned segmentation technique. **Animal**, Cambridge, v. 9, n. 11, p. 1859-1865, 2015.

OCZAK, M.; VIAZZI, S.; ISMAYILOVA, G.; SONODA, L. T.; ROULSTON, N.; FELS, M.; BAHR, C.; HARTUNG, J.; GUARINO, M.; BERCKMANS, D. Classification of aggressive behaviour in pigs by activity index and multilayer feed forward neural network. **Biosystems Engineering**, London, v. 119, p. 89-97, 2014.

OLIVEIRA, D. C. G. **Percepção de suínos em relação ao ambiente térmico promovido por diferentes sistemas de resfriamento**. 2015. 86 f. Tese (Doutorado) – Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga, 2015.

OLIVEIRA, M. V. G. **Influência do enriquecimento ambiental no comportamento e desempenho de leitões na fase de creche**. 2016. 66 f. Dissertação (Mestrado) - Universidade Federal de Goiás, Goiânia, 2016.

OLIVEIRA, D. C. G.; CAMPOS, M. S.; PASSÉ-COUTRIN, N.; POTIRON, C. O.; BILBA, K.; ARSÈNE, Marie-Ange; SAVASTANO JUNIOR, H. Modeling of the thermal performance of

piglet house with non-conventional floor system. **Journal of Building Engineering**, [s.l.], v. 35, p. 102071, 2021.

OXHOLM, L. C.; STEINMETZ, H.V.; LAHRMANN, H.P.; NIELSEN, M.B.F.; AMDI, C.; HANSEN, C. F. Behaviour of liquid-fed growing pigs provided with straw in various amounts and frequencies. **Animal**, Cambridge, v. 8, n. 11, p. 1889-1897, 2014.

PACHECO, V. M.; SOUSA, R. V.; RODRIGUES, A. V. S.; SARDINHA, E. J. S.; MARTELLO, L. S. Thermal imaging combined with predictive machine learning based model for the development of thermal stress level classifiers. **Livestock Science**, Amsterdam, v. 241, p. 104244, 2020.

PANDORFI, H.; SILVA, I. J. O.; GUISELINI, C.; PIEDADE, S. M. S. Uso da lógica fuzzy na caracterização do ambiente produtivo para matrizes gestantes. **Engenharia Agrícola**, Jaboticabal, v. 27, n. 1, p. 83-92, 2007.

PANDORFI, H.; SILVA, I. J. O.; SARNIGHAUSEN, V. C. R.; VIEIRA, F. M. C.; NASCIMENTOS, S. T.; GUISELINI, C. Uso de redes neurais artificiais para predição de índices zootécnicos nas fases de gestação e maternidade na suinocultura. **Revista Brasileira de Zootecnia**, Viçosa, v. 40, n. 3, p. 676-681, 2011.

PARREIRA, D. P.; VALENTIM, J. K.; GERALDO, A.; FARIA, S. R.; MEDEIROS, S. L. S.; MENDES, J. P.; SILVA, A. F.; PIETRAMALE, R. T. R. Suínos em fase de terminação mantidos em ambiente enriquecido. **Caderno de Ciências Agrárias**, Montes Claros, v. 13, p. 1-6, 31 2021.

PATRÍCIO, D. I.; RIEDER, R. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. **Computers and electronics in agriculture**, Cambridge, v. 153, p. 69-81, 2018.

POLETTI, R. Bem-estar animal. **Suíno.com**. Tangará, 2010. Série especial bem-estar animal por Rosângela Poletto. Disponível em: <http://tinyurl.com/4t6z4bk>. Acesso em: 05 dez. 2019.

QUINIOU, N.; MASSABIE, P.; GRANIER, R. Diurnally variation of ambiente temperature around 24 or 28°C: influence on performance and feeding behavior of growing pigs. *In*: SWINE HOUSING INTERNATIONAL CONFERENCE, 1., 2000, Des Moines. **Proceedings** [...]. St. Joseph: ASAE, 2000a. p. 332-339.

QUINIOU, N.; RENAUDEAU, D.; DUBOIS, S.; NOBLET, J. Influence of high ambient temperatures on food intake and feeding behaviour of multiparous lactating sows. **Animal Science**, Penicuik, v. 70, n. 3, p. 471-479, 2000b.

RADOSTITS, O. M.; MAYHEW, I. G. J.; HOUSTON, D. M. **Exame clínico e diagnóstico em veterinária**. Rio de Janeiro: Guanabara Koogan, 2002.

RODRÍGUEZ, L. F. P. **Bagaço de cana como enriquecimento ambiental para leitões recém desmamados**. 2016. 64 f. Dissertação (Mestrado) – Faculdade de Zootecnia e Engenharia de Alimentos, Pirassununga, 2016.

SAMPAIO, C. A. P. **Caracterização dos ambientes térmicos, aéreo e acústico em sistemas de produção de suínos, nas fases de creche e terminação**. 2004. 151f. Tese (Doutorado) – Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 2004.

SANTOS, T. C.; CARVALHO, C. C. S.; SILVA, G. C.; DINIZ, T. A.; SOARES, T. E.; MOREIRA, S. J. M.; CECON, P. R. Influência do ambiente térmico no comportamento e desempenho zootécnico de suínos. **Revista de Ciências Agroveterinárias**, Lages, v. 17, n. 2, p. 241-253, 19 2018.

SANTOS, J. V.; FARIAS, S. S.; PEREIRA, T. L.; TEIXEIRA, C. P.; TITTO, C. G. Preference for and maintenance of interest in suspended enrichment toys in confined growing pigs. **Journal of Veterinary Behavior**, New York, v. 45, p. 68-73, 2021.

SARTOR, V. *et al.* Efeito do resfriamento evaporativo no desempenho de suínos em fase de terminação. **Engenharia na Agricultura**, Viçosa, v. 11, n. 4, p. 58-64, 2003.

SCHORMANN, R.; HOY, S. Effects of room and nest temperature on the preferred lying place of piglets: a brief note. **Applied Animal Behavior Science**, Amsterdam, v. 101, n. 3-4, p.369-74, 2006.

SHAH, V.; JAIN, K.; MAHESHWARI, C. V. Combined parametric evaluation of Kamod rice using artificial neural network. **International Journal of Communication System and Network**, [s.l.], v. 1, p. 1-6, 2016.

SILVA, I. J. O. **Automação dos sistemas para aumento do conforto animal**. 2008. Disponível em: <http://www.nupea.esalq.usp.br/noticias/producao>. Acesso em: 15 nov. 2019.

SILVA, I. J. O. Sistemas naturais e artificiais do controle do ambiente: climatização. *In*: SILVA, I. J. O. (ed.). **Ambiência e qualidade na produção industrial de suínos**. Piracicaba: Fundação de estudos agrários “Luiz de Queiroz”, 1999. p. 81-112.

SILVA, L. A.; PERES, S. M.; BOSCARIOLI, C. **Introdução à mineração de dados: com aplicações em R**. Rio de Janeiro: Elsevier, 2016.

SNOWDON, C. T. O significado da pesquisa em comportamento animal. **Estudos de Psicologia**, Natal, v. 4, n. 2, p. 365-373, 1999.

SOBESTIANSKY, J.; ZANELLA, J. R. C. Formas anormais de comportamento. *In*: SOBESTIANSKY, J.; BARCELLOS, D. E. S. N. (org.). **Doenças dos suínos**. Goiânia: Cãnone Editorial, 2007. p. 579-592.

SOERENSEN, D. D.; PEDERSEN, L. J. Infrared skin temperature measurements for monitoring health in pigs: a review. **Acta Veterinaria Scandinavica**, London, v. 57, art. 5, 2015.

SOUSA, G. H. N.; OLIVEIRA, M. R. A.; MAGALHÃES, N. A.; REIS, M. L.; PORTELA, G. L. F.; LUZ, C. S. M.; SOUSA JÚNIOR, S. C. Environmental enrichment to pigs in initial phase. **Nucleus Animalium**, [s.l.], v. 10, n. 2, p. 23-33, 30 2018.

SPOOLDER, H. A. M.; AARNINK, A. A. J.; VERMEER, H. M.; VAN RIEL, J.; EDWARDS, S. A. Effect of increasing temperature on space requirements of group housed finishing pigs. **Applied Animal Behaviour Science**, Amsterdam, v. 138, n. 3-4, p. 229-239, 2012.

SWARUP, P.; CHEN, P.; HOU, R.; QUE, P.; LIU, P.; KONG, A. W. K. Giant panda behaviour recognition using images. **Global Ecology and Conservation**, [s./], v. 26, p. 1510, 2021.

SYKES, D. J.; COUVILLION, J. S.; CROMIAK, A.; BOWERS, S.; SCHENCK, E.; CRENSHAW, M.; RYAN, P. L. The use of digital infrared thermal imaging to detect estrus in gilts. **Theriogenology**, Los Altos, v. 78, n. 1, p. 147-152, 2012.

TAVARES, S. L. S. *et al.* Influência da temperatura ambiente sobre o desempenho e os parâmetros fisiológicos de suínos machos castrados dos 30 aos 60kg. **Revista Brasileira de Zootecnia**, Viçosa, v. 29, n. 1, p. 199-205, 2000.

TOLON, Y. *et al.* Ambiência térmica, aérea e acústica para reprodutores suínos. **Engenharia Agrícola**, Jaboticabal, v. 30, n. 1, p. 1-13, 2010.

TULLO, E. *et al.* Application note: labelling, a methodology to develop reliable algorithm in PLF. **Computers and electronics in agriculture**, Cambridge, v. 142, p. 424-428, 2017.

TURNER, L. W. *et al.* Fan, sprinkler, and sprinkler plus fan systems for cooling growing-finishing swine. Proceedings of the ASAE. **Annual International Meeting**, Minneapolis, Minnesota, v. 3, 1997. 14 p.

VIAZZI, S.; ISMAYILOVA, G.; OCZAK, M.; SONODA, L. T.; FELLS, M.; GUARINO, M.; VRANKEN, E.; HARTUNG, J.; BAHR, C.; BERCKMANS, D. Image feature extraction for classification of aggressive interactions among pigs. **Computers and Electronics in Agriculture**, Cambridge v. 104, p. 57-62, 2014.

VIEIRA, F. M. C.; SILVA, I. J. O.; BARBOSA FILHO, J. A. D. *et al.* Productive losses on broiler preslaughter operations: effects of the distance from farms to abattoirs and lairage time in a climatized holding área. **Revista Brasileira de Zootecnia**, Viçosa, v. 39, p. 2471-2476, 2010.

VOERMANS, J. A. M., MONTENY, G. On ammonia and odour control from animal production facilities. *In*: INTERNATIONAL CONGRESS ON AGRICULTURAL ENGINEERING, 13., Rabat, Morocco, 1997. **Proceedings** [...]. Rabat, Morocco, 1997. p. 23-31.

YÁÑEZ-PIZAÑA, A.; MOTA-ROJAS, D.; RAMÍREZ-NECOECHEA, R.; CASTILLO-RIVERA, M.; ROLDÁN-SANTIAGO, P.; MORA-MEDINA, P.; GONZÁLEZ-LOZANO, M. Application of infrared thermography to assess the effect of different types of environmental enrichment on the ocular, auricular pavilion and nose area temperatures of weaned piglets. **Computers and Electronics in Agriculture**, Cambridge v. 156, p. 33-42, 2019.

YANG, Q; XIAO, D; LIN, S. Feeding behavior recognition for group-housed pigs with the Faster R-CNN. **Computers and Electronics in Agriculture**, Cambridge v. 155, p. 453-460, 2018.

ZANELLA, A. J. Indicadores fisiológicos e comportamentais do bem-estar animal. **A Hora Veterinária**, Porto Alegre, v. 14, n. 83, p. 47-52, 1995.

ZAREIFOROUGH, H. *et al.* Potential applications of computer vision in quality inspection of rice: A review. **Food Engineering Reviews**, [s./], v. 7 p. 321–345, 2015.

ZHANG, Y.; CAI, J.; XIAO, D.; LI, Z.; XIONG, B. Real-time sow behavior detection based on deep learning. **Computers and Electronics in Agriculture**, Cambridge, v. 163, art. 104884, 2019.

ZHENG, C. *et al.* Automatic recognition of lactating sow postures from depth images by deep learning detector. **Computers and Electronics in Agriculture**, Cambridge v. 147, n. p. 51-63, 2018.