

UNIVERSIDADE FEDERAL DE UBERLÂNDIA  
FACULDADE DE MEDICINA VETERINÁRIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS VETERINÁRIAS

ANA CAROLINE RODRIGUES DA CUNHA

**USO DE IMAGENS DIGITAIS PARA PREDIÇÃO DO PESO CORPORAL EM  
SUÍNOS CRUZADOS**

UBERLÂNDIA – MG

2022

ANA CAROLINE RODRIGUES DA CUNHA

**USO DE IMAGENS DIGITAIS PARA PREDIÇÃO DO PESO CORPORAL EM  
SUÍNOS CRUZADOS**

Dissertação apresentada à Faculdade de Medicina Veterinária da Universidade Federal de Uberlândia como requisito parcial para obtenção do título mestre em Ciências Veterinárias.

Área de concentração: Produção Animal

Orientador: Prof. Dr. Robson Carlos Antunes

Coorientadora: Profa. Dra. Adriana Santana do Carmo

UBERLÂNDIA - MG

2022

ANA CAROLINE RODRIGUES DA CUNHA

**USO DE IMAGENS DIGITAIS PARA PREDIÇÃO DO PESO CORPORAL EM  
SUÍNOS CRUZADOS**

Dissertação apresentada à Faculdade de Medicina Veterinária da Universidade Federal de Uberlândia como requisito parcial para obtenção do título mestre em Ciências Veterinárias.

Área de concentração: Produção Animal

Uberlândia – MG, 24/02/2022.

Banca Examinadora:

---

Profa. Dra. Adriana Santana do Carmo – Coorientadora (EVZ/UFG)

---

Prof. Dr. Lúcio Vilela Carneiro Girão – Docente Adjunto (FAMEV/UFU)

---

Dra. Carla Daniela Sugimoto Leite – Pesquisadora de pós-doutorado no Centro de Pesquisa em Alimentos (EVZ/UFG)

Dedico este trabalho aos meus pais, Cláudia e Amaury, pelo estímulo, carinho e compreensão.

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU  
com dados informados pelo(a) próprio(a) autor(a).

C972 Cunha, Ana Caroline Rodrigues da, 1995-  
2022 Uso de imagens digitais para a predição de peso  
corporal em suínos cruzados [recurso eletrônico] / Ana  
Caroline Rodrigues da Cunha. - 2022.

Orientador: Robson Carlos Antunes.  
Coorientadora: Adriana Santana do Carmo.  
Dissertação (Mestrado) - Universidade Federal de  
Uberlândia, Pós-graduação em Ciências Veterinárias.  
Modo de acesso: Internet.  
Disponível em: <http://doi.org/10.14393/ufu.di.2022.107>  
Inclui bibliografia.  
Inclui ilustrações.

1. Veterinária. I. Antunes, Robson Carlos, 1968-,  
(Orient.). II. Carmo, Adriana Santana do, 1983-,  
(Coorient.). III. Universidade Federal de Uberlândia.  
Pós-graduação em Ciências Veterinárias. IV. Título.

CDU: 619

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091



**UNIVERSIDADE FEDERAL DE UBERLÂNDIA**  
Secretaria da Coordenação do Programa de Pós-Graduação em Ciências  
Veterinárias

BR 050, Km 78, Campus Glória, Uberlândia-MG, CEP 38400-902  
Telefone: (34) 2512-6811 - www.ppgcv.famev.ufu.br - mesvet@ufu.br



### ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	CIÊNCIAS VETERINÁRIAS				
Defesa de:	DISSERTAÇÃO DE MESTRADO ACADÊMICO Nº PPGCVET/ 007/2022				
Data:	24 de fevereiro de 2022	Hora de início:	14:00	Hora de encerramento:	17:00
Matrícula do Discente:	12012MEV002				
Nome do Discente:	<b>ANA CAROLINE RODRIGUES DA CUNHA</b>				
Título do Trabalho:	Uso de imagens digitais para predição do peso corporal em suínos cruzados				
Área de concentração:	Produção Animal				
Linha de pesquisa:	Manejo e eficiência de produção dos animais, seus derivados e subprodutos				
Projeto de Pesquisa de vinculação:	Investigação científica dos fatores que afetam e influenciam o desempenho e eficiência dos suínos nas várias fases de produção e qualidade da carcaça e carne				

Reuniu-se por Videoconferência (meio eletrônico), da Universidade Federal de Uberlândia, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Ciências Veterinárias, assim composta: Professores Doutores: **Lúcio Vilela Carneiro Girão - UFU; Carla Daniela Suguimoto Leite - UFG; Adriana Santana do Carmo - UFG** co-orientador(a) do(a) candidato(a).

Iniciando os trabalhos o(a) presidente da mesa, Dr(a). Adriana Santana do Carmo, apresentou a Comissão Examinadora e o candidato(a), agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado(a).

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Lucio Vilela Carneiro Girao, Professor(a) do Magistério Superior**, em 24/02/2022, às 17:23, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).

---



Documento assinado eletronicamente por **Adriana Santana do Carmo, Usuário Externo**, em 24/02/2022, às 17:23, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).

---



Documento assinado eletronicamente por **Carla Daniela Suguimoto Leite, Usuário Externo**, em 24/02/2022, às 18:07, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).

---



A autenticidade deste documento pode ser conferida no site [https://www.sei.ufu.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **3364827** e o código CRC **A543FAC2**.

---

## AGRADECIMENTOS

A Deus, por estar sempre guiando o meu caminho e me ajudando a superar todos os obstáculos que apareceram. Agradeço imensamente também à Ele por permitir que eu pudesse concluir o sonhado mestrado em tempos de pandemia e ao mesmo tempo auxiliando nos cuidados de saúde do meu pai, vítima de um AVC. Aos meus pais, Amaury e Claudia, por toda compreensão diante do que passamos, por se esforçarem e terem paciência em me ajudar, pelo apoio financeiramente ao primeiro ano do mestrado sem bolsa e nesta etapa tão importante de nossas vidas.

Aos meus avós Vera e João, por me amarem tanto, sempre preocupados com meu bem-estar, felicidade e sucesso, sempre fazendo esforço para estarmos juntos e, com certeza, a vinda de vocês para Uberlândia me proporcionou muito conforto em meu coração. Também agradeço aos meus tios, Adriana e Rafael, meus irmãos-primos de coração, Laís e Henrique, pelo carinho e amor em toda minha vida. Agradeço também aos meus colegas do PPGCV, da graduação em Zootecnia e aos demais de longa data importantes para mim nessa trajetória, pelo incentivo, apoio, carinho e amizade.

Ao meu orientador, Prof. Robson Carlos Antunes, por ter aceitado esse desafio juntamente com à minha coorientadora, Profa. Dra. Adriana Santana do Carmo, por toda sua paciência e dedicação para fazermos este trabalho e por ter sido um enorme apoio tanto profissionalmente quanto pessoalmente, me ajudando sempre tornar uma profissional melhor e com maior conhecimento. Agradeço imensamente pelo aceite em me coorientar à distância, fazendo a “ponte” Goiânia-Uberlândia e por depositar sua confiança em mim de que iríamos fazer um excelente trabalho.

Ao Prof. Dr. Geovanne Ferreira Rebouças (PPGZ/UFG), juntamente com as alunas de graduação da EVZ/UFG, Naia e Haílla, pela ajuda na coleta de dados no IF Goiano, foram de imenso valor para que eu pudesse concluir com sucesso meu mestrado. Agradeço também ao IF Goiano, campus Urutaí, por nos receber e dar todo suporte no setor de suinocultura para a coleta de dados da minha pesquisa, sob a supervisão do Zootecnista Eduardo de Faria Viana.

Ao Prof. Dr. Lúcio Vilela Carneiro Girão e a Dra. Carla Daniela Suguimoto Leite, por terem aceitado participar da minha banca de defesa, contribuindo assim ainda mais com minha pesquisa e meu sucesso profissional. Agradeço também ao Prof. Dr. Arthur dos Santos Mascioli, pelo aceite quanto à minha participação como aluna especial na disciplina “Princípios



de Melhoramento Genético” (PPGZ/UFU), contribuindo sem dúvidas para meu crescimento e conhecimento na área do Melhoramento Genético Animal.

A FAPEMIG, pela concessão da bolsa de mestrado, permitindo assim que eu pudesse concluir meu mestrado por meio do auxílio financeiramente. Agradeço também por todo apoio da Coordenação do PPGCV/UFU, em especial à Célia e Ana Carolina, quanto às informações fornecidas remotamente em tempos de pandemia, contribuindo para o sucesso do mestrado.

“E guardemos a certeza, pelas próprias dificuldades já superadas, de que não há mal que dure para sempre”.

(Chico Xavier, 2019, psicografado).

## RESUMO

O desenvolvimento de tecnologias possibilitou a captura de imagens digitais por sensores de profundidade afim de obter medidas morfométricas que podem ser utilizadas no desenvolvimento de modelos matemáticos para a predição do peso corporal em animais. Com isto, objetivou-se o desenvolvimento de modelos matemáticos para predizer o peso corporal em suínos cruzados a partir de medidas morfométricas obtidas com imagens digitais bidimensionais. A coleta de dados foi conduzida no setor de suinocultura do IF Goiano, campus Urutaí, em 52 suínos cruzados alojados na fase de terminação. Os animais foram pesados aleatoriamente e filmados pela câmera do sensor de profundidade Microsoft Kinect® v1 na visão dorsal. Posteriormente, os mesmos foram conduzidos para a mensuração das medidas morfométricas manuais, sem contenção, sendo elas o comprimento dorsal, circunferência peitoral e flanco, largura peitoral e flanco, altura peitoral e flanco e a profundidade. Posteriormente, foram capturadas as imagens laterais dos animais pelo telefone móvel. Seguindo os critérios de qualidade de imagem, selecionou-se apenas 1 frame por animal e, juntamente com as imagens laterais, totalizando-se 52 imagens laterais e 52 imagens dorsais. As medidas morfométricas mensuradas a partir das imagens laterais foram o comprimento lateral, altura peitoral e flanco, profundidade, área e perímetro lateral. Já as medidas morfométricas a partir das imagens dorsais foram o comprimento dorsal, largura peitoral, flanco e abdominal, área e perímetro dorsal. Foi estimada a correlação de Pearson entre o PC e as medidas morfométricas. Os modelos matemáticos foram elaborados pelas metodologias da regressão linear múltipla (RLM) e suporte de vetor de regressão (SRV) para a predição do peso corporal. Após a identificação dos modelos mais adequados para predizer o peso corporal, foi estimado o peso médio predito por cada uma das equações selecionadas pelo método RLM e SVR e validado com o peso médio real. Todas as correlações de Pearson entre o peso corporal real e as medidas morfométricas reais e preditas pelas imagens digitais foram positivas de magnitude moderada à alta e estatisticamente significativas ( $P < 0,05$ ). A diferença entre o peso corporal real e o predito pelo SVR e RLM por meio das mensurações reais foi de -400 g e -1,95 kg, respectivamente. O melhor modelo a partir da análise RLM e mais próximo ao real foi o obtido pelas medidas morfométricas das imagens dorsais, sendo que estas explicam 91% da variância do PC predito e com 3,83 kg acima do real. Quanto à análise por SVR, o melhor modelo de predição do peso corporal foi o combinado de imagens dorsais e laterais, com coeficiente de determinação de 98%. Os modelos matemáticos desenvolvidos a partir das medidas morfométricas preditas pelas imagens digitais provaram ter potencial para estimar o peso corporal de suínos cruzados utilizando-se medidas morfométricas como o comprimento dorsal, profundidade e largura peitoral. O método SVR se mostrou mais eficiente na predição do peso corporal por meio das medidas morfométricas de comprimento e área dorsal, altura e largura peitoral.

**Palavras-chave:** Regressão Linear Múltipla. Sensor de profundidade. Suinocultura. Support Vector Regression.

## ABSTRACT

The technologies development made it possible to estimate morphometric measurements by digital images captured by depth sensors, that can be used in the development of mathematical models for the prediction of body weight in animals. The objective of the present work was to develop mathematical models to predict body weight in crossbred pigs from morphometric measurements obtained with two-dimensional digital images. The data collection was carried out in the swine sector of IF Goiano, Urutai campus, in 52 crossbred pigs housed in the growing-finishing phase. The animals were randomly weighed and filmed by the Microsoft Kinect® v1 depth sensor camera in the dorsal view. Subsequently, they were conducted for the measurement of manual morphometric traits, without restraint, being the dorsal length, heart girth and flank circumference, heart girth and flank width, heart girth and flank height and depth. And, finally, the lateral images of the animals were captured by the mobile phone. Following the image quality criteria, only one frame per animal was selected and, together with the lateral images, a total of 52 lateral images and 52 dorsal images were selected. The morphometric traits measured from the lateral images were the lateral length, heart and flank height, depth, lateral area, and perimeter. The morphometric measurements from the dorsal images were the dorsal length, heart, flank, abdominal width, the dorsal area, and perimeter. Pearson's correlations between morphometric variables and body weight and mathematical models were developed using Multiple Linear Regression (MLR) and Support Vector Regression (SVR) methodologies for bodyweight prediction. After identifying the most suitable models to predict body weight, the average weight predicted by each of the equations selected by the MLR and SVR method was estimated and validated with the real average body weight. All Pearson correlations between real bodyweight and real and predicted morphometric measurements by digital images were moderate to high magnitude positive and statistically significant. The difference between the real bodyweight and predicted by the SVR and MLR through the real measurements was -400 g and -1.95 kg, respectively. The best model from the MLR analysis and closest to the real one was the one obtained by the morphometric measurements of the dorsal images, which explain 91% of the variance of the predicted body weight and with 3.83 kg above the real one. As for the analysis by SVR, the best model for predicting body weight presented 98% of the determination coefficient. The mathematical models developed from the morphometric measurements predicted by the digital images proved to have the potential to estimate the bodyweight of crossbred pigs from measurements such as dorsal length, depth, and heart width. The SVR method proved to be more efficient in predicting body weight through morphometric measurements of length and dorsal area, height, and heart girth width.

**Keywords:** Depth sensor. Multiple Linear Regression. Pig farming. Support Vector Regression

## LISTA DE TABELAS

Tabela 1 - Estatística descritiva das variáveis reais de PC (kg) e das medidas morfométricas reais (cm). .....	33
Tabela 2 - Estatística descritiva das medidas morfométricas a partir das imagens laterais (cm)*. ....	33
Tabela 3 - Estatística descritiva das variáveis de PC (kg) e das medidas morfométricas retiradas das imagens dorsais (cm)** .....	34
Tabela 4 - Correlação linear de Pearson (acima da diagonal) e valores de significância (abaixo da diagonal) entre o PC real e as medidas morfométricas reais. ....	35
Tabela 5 - Correlação linear de Pearson (acima da diagonal) e valores de significância (abaixo da diagonal) entre o PC real e as medidas morfométricas preditas pelas imagens laterais. ....	36
Tabela 6 - Correlação linear de Pearson entre o PC real (acima da diagonal) e valores de significância (abaixo da diagonal) e as medidas morfométricas preditas pelas imagens dorsais** .....	37
Tabela 7 - Modelos selecionados para a predição do PC a partir da modelagem matemática RLM e SVR. ....	39
Tabela 8 - Estatística descritiva das medidas morfométricas a partir das imagens laterais* em pixels.....	51
Tabela 9 - Estatística descritiva das medidas morfométricas retiradas das imagens dorsais** em pixels.....	51
Tabela 10 - Variáveis preditoras e seus índices para o modelo matemático completo a partir das imagens reais a partir da metodologia RLM. ....	52
Tabela 11 - Variáveis preditoras e seus índices para o modelo matemático completo a partir das imagens laterais* a partir da metodologia RLM. ....	53
Tabela 12 - Variáveis preditoras e seus índices para o modelo matemático completo a partir das imagens dorsais** a partir da metodologia RLM.....	53
Tabela 13 - Variáveis preditoras e seus índices para o modelo matemático completo a partir das imagens laterais* + dorsais** a partir da metodologia RLM.....	54

## LISTA DE ILUSTRAÇÕES

Figura 1 - Pesagem e filmagem dos animais. ....	24
Figura 2 - Imagem em RGB obtido a partir da gravação em "Color" pelo Kinect® Studio....	25
Figura 3 - Imagem RGB bidimensional obtida com telefone móvel.....	26
Figura 4 - Esquematização das medidas morfométricas de CD, AP, AF, CP, CF e P. ....	27
Figura 5 - Esquematização das medidas morfométricas reais de LP e LF realizadas em suínos cruzados.....	28
Figura 6 - Contagem de pixels e conversão pela equivalência de 88027 <i>pixels</i> para 1 <i>cm real</i> . .....	29
Figura 7 - Processamento da imagem lateral no ImageJ2. ....	30
Figura 8 - Processamento da máscara retirada do frame dorsal no ImageJ2.....	30

## LISTA DE ABREVIATURAS E SIGLAS

AD - Área Dorsal  
AIC - *Akaike Information Criteria*  
AF - Altura Flanco  
AL - Área Lateral  
AP - Altura Peitoral  
CD - Comprimento Dorsal  
CL - Comprimento Lateral  
CP - Circunferência Peitoral  
CV - Coeficiente de Variação  
DP - Desvio Padrão  
ECC - Escore de Condição Corporal  
EPR - Erro entre Predito-Real  
ET - Espessura de Toucinho  
GPD - Ganho de Peso Diário  
IDC - Intervalo Desmame-Cio  
LF - Largura Flanco  
LP - Largura Peitoral  
LA - Largura Abdominal  
MAE - *Mean Absolut Error*  
P - Profundidade  
PA - Peso ao Abate  
PC - Peso Corporal  
PD - Perímetro Dorsal  
PL - Perímetro Lateral  
PSA - Peste Suína Africana  
PV - Peso Vivo  
RMSE - *Root Mean Squared Error*  
RLM - Regressão Linear Múltipla  
SRM - *Support Vector Machine*  
SVR - *Support Vector Regression*  
VIF - *Variance Inflation Factor*

## SUMÁRIO

<b>1. INTRODUÇÃO.....</b>	<b>15</b>
<b>2. OBJETIVOS.....</b>	<b>16</b>
2.1 OBJETIVO GERAL.....	16
2.2 OBJETIVOS ESPECÍFICOS .....	16
<b>3. REVISÃO BIBLIOGRÁFICA .....</b>	<b>16</b>
3.1 PANORAMA DA SUINOCULTURA.....	16
3.2 IMPORTÂNCIA DO PESO CORPORAL E SUA RELAÇÃO COM MEDIDAS MORFOMÉTRICAS.....	18
3.3 O USO DE VISÃO COMPUTACIONAL PARA A PREDIÇÃO DO PESO CORPORAL.....	19
3.4 MODELAGEM MATEMÁTICA PARA A PREDIÇÃO DE PESO CORPORAL ....	21
3.4.1 Regressão Linear Múltipla (RLM).....	21
3.4.2 Regressão por Vetor de Suporte de Máquina (SVR - <i>Support Vector Regression</i> )	22
<b>4. METODOLOGIA.....</b>	<b>23</b>
4.1 CARACTERIZAÇÃO DO LOCAL DE EXPERIMENTO E DOS ANIMAIS.....	23
4.2 COLETA DE DADOS .....	23
4.3 ANÁLISE E PROCESSAMENTO DAS IMAGENS .....	28
4.4 ANÁLISE ESTATÍSTICA.....	30
4.4.1 Análise de consistência e descritiva dos dados .....	30
4.4.2 Validação dos modelos selecionados .....	32
<b>5. RESULTADOS E DISCUSSÃO.....</b>	<b>33</b>
<b>6. CONCLUSÃO.....</b>	<b>41</b>
<b>ANEXOS .....</b>	<b>51</b>
<b>ANEXO A – TABELAS DA ANÁLISE ESTATÍSTICA.....</b>	<b>51</b>



## 1. INTRODUÇÃO

O Peso Corporal (PC) é uma característica fenotípica utilizada na produção de suínos e pode determinar situações da cadeia como o número de dias de alojamento dos animais em cada fase e do Intervalo Desmame-Cio (IDC), momento ideal para a realização da primeira inseminação artificial em leitoas, quantidade de ração fornecida diariamente por meio do consumo diário de ração relacionado ao alto custo de produção com a alimentação, curva de crescimento dos animais por meio do Ganho de Peso Diário (GPD), identificação de animais de baixo e alto desempenho pela seleção genética, desmame precoce de leitões, previsão de abate, densidade do lote, teste de granja para seleção de reprodutores e matrizes, conversão e eficiência alimentar e outros. Contudo, a condução dos animais aos equipamentos de pesagem, como a balança digital ou mecânica, pode ser trabalhosa e demorada, atrapalhando a rotina diária, além de aumentar a possibilidade de estresse aos animais (CANG; HE; QIAO, 2019; KAEWTAPEE; RAKANGTONG; BUNCHASAK, 2019).

Estudos tem demonstrado que o PC pode ser predito por meio do uso de tecnologias desenvolvidas e aplicadas pela análise e processamento de imagens digitais obtidas por sensores de profundidade, levando em consideração a importância da correlação linear entre as medidas morfométricas dos animais e o PC mensurado manualmente pela balança na propriedade (KONGSRO, 2014).

Além do mais, o uso de imagens poderia substituir a mensuração da Espessura de Toucinho (ET), comumente utilizada na suinocultura para avaliar os animais ao invés de pesá-los, bem como auxiliar na obtenção do Escore de Condição Corporal (ECC) para avaliação do estado nutricional. Diferentemente das mensurações manuais, o uso de câmeras e sensores para obtenção de fenótipos possui vantagens como a maior rapidez na coleta das informações, redução da carga de trabalho dos funcionários, menor custo de manutenção em comparação ao trabalho manual e menor interferência na rotina dos animais. (TSCHARKE; BANHAZI, 2013; MOROTA; VENTURA; SILVA, 2018).

As imagens digitais podem ser capturadas por câmeras e, posteriormente, analisadas e processadas por programas computacionais em mapas numéricos que possibilitam a realização de diferentes mensurações pela contagem de pixels, apresentando muitas aplicações na agricultura e na pecuária afim de reduzir os custos, aumentar a velocidade de obtenção de dados e dessa forma, auxiliar na tomada de decisão do produtor (CONDOTTA et al., 2018; ZHU et al., 2015).

## 2. OBJETIVOS

### 2.1 OBJETIVO GERAL

Objetivou-se o desenvolvimento de modelos matemáticos para prever o peso corporal em suínos cruzados a partir de medidas morfométricas obtidas com imagens digitais bidimensionais.

### 2.2 OBJETIVOS ESPECÍFICOS

- Desenvolver modelos de predição matemáticos para peso corporal de suínos cruzados por meio de medidas morfométricas obtidas com imagens digitais bidimensionais pelas metodologias RLM e SVR;
- Avaliar os modelos matemáticos de predição obtidos com imagens obtidas na posição lateral e dorsal dos animais pelas metodologias RLM e SVR;
- Comparar a eficiência de predição do PC obtido a partir de medidas morfométricas coletadas nos animais manualmente e pela visão computacional.

## 3. REVISÃO BIBLIOGRÁFICA

### 3.1 PANORAMA DA SUINOCULTURA

Levantamentos realizados em 2020 apontam que o rebanho suinícola mundial contém 677,6 milhões de animais, produzindo 106,53 milhões de toneladas de carne, o que demonstra a grande importância da cadeia produtiva dessa espécie (FAO, 2020). O suíno doméstico (*Sus scrofa domesticus*) é criado no mundo todo com o objetivo principal de produção de cortes cárneos *in natura*, entretanto, o Brasil também exporta outros subprodutos como os miúdos, industrializados, gorduras, couros e peles (ABPA, 2020). A suinocultura brasileira ocupa o quarto lugar no *ranking* de produção, com 4,436 milhões de toneladas de carne, quinto lugar em consumo com 16 kg per capita/ano e o quarto lugar dentre os países exportadores, com 1,250 milhões de toneladas (ABPA, 2021).

Apesar da espécie se destacar no volume de produção, desde 2018 encontra-se em segundo lugar no que se refere ao consumo mundial de carne, perdendo a primeira posição para a carne de frango. Dentre os diversos fatores que ocasionaram essa perda de posição, podemos

citar o aumento de preço do produto final devido à redução da produção e a disponibilidade da carne suína como oferta de abastecimento aos países importadores desde o surto de Peste Suína Africana (PSA) que se espalhou globalmente, afetando o comércio chinês, principal mercado produtor de carne suína (WOONWONG; TIEN; THANAWONGNUWECH, 2020).

Com isto, a produção de suínos foi fortemente afetada pela PSA e toda a cadeia produtiva sofreram enormes perdas por problemas sanitários e erradicação de doenças que, conforme recomendado pelas diretrizes internacionais, exige a eliminação de animais infectados. Além disso, a propriedade deve passar por uma quarentena durante a qual toda a produção cessa e, por consequência, ocorrem reduções da produtividade total da carne suína (FREITAS; LYRA, 2018; DANZETTA et al., 2020).

Apesar disso, o consumo mundial de carne suína vem aumentando e, nos últimos 20 anos, em 58% e as razões pelo qual contribuíram foram tanto o crescimento populacional quanto o aumento de renda. Contudo, os países desenvolvidos são os principais responsáveis pelo incremento no consumo de carne *per capita*, já que nos países em desenvolvimento, o consumo manteve-se praticamente estável (WHITNALL; PITTS, 2019). No Brasil, uma parcela significativa da população não consome carne suína devido, principalmente, aos mitos relacionados à biosseguridade e sanidade dos animais criados no passado de forma extensiva e semiextensiva, o que tem limitado o consumo da proteína, porém atualmente, aproximadamente 98% da produção ocorre em sistemas intensivos e com alto nível de controle da sanidade (GUIMARÃES et al., 2017).

A cadeia produtiva da carne suína possui diferentes níveis tecnológicos, como o Sistema de Criação ao Ar Livre (SISCAL), semiextensivo e o Sistema de Confinamento (SISCON), tendo sido aprimorada ao longo dos anos quanto à eficiência da produtividade, principalmente no que se refere ao aumento do volume de carne suína produzida que, por consequência, tem repercussão na quantidade exportada e distribuída para consumo interno. Além do mais, a quantidade de carne suína a ser produzida é influenciada pelo consumo populacional e este por sua vez, pelas variáveis preço e qualidade do produto final (ABCS, 2016).

Em geral, nos últimos 40 anos, a suinocultura no Brasil vem passando por grandes mudanças de organização da cadeia produtiva e com a chegada de novas tecnologias, estão ocorrendo transformações nas áreas de genética, nutrição, administração de negócios, o que resulta em propriedades não somente adaptadas para aumentar o número e peso de animais abatidos, mas também para propiciar o bem-estar dos animais (SILVA et al., 2019; WU; BAZER, 2019).

### 3.2 IMPORTÂNCIA DO PESO CORPORAL E SUA RELAÇÃO COM MEDIDAS MORFOMÉTRICAS

O PC de suínos na fase de crescimento e terminação é considerado um parâmetro importante para auxiliar na determinação das estratégias nutricionais e na idade ao abate, uma vez que possibilita selecionar animais com melhor conversão alimentar para maior lucratividade, demonstrando que o monitoramento preciso e acurado de ganho de peso animal (GPD) e peso de abate (PA) é crucial para uma tomada de decisão eficiente na produção animal (DOUGLAS et al., 2015; MATTHEWS et al., 2016; WANG et al., 2018).

A obtenção do PC pode ser realizada pelo método direto, por meio da pesagem do animal em balança, ou indiretamente, no qual envolve estimar o peso por meio da associação entre medidas morfométricas e o PC, além do auxílio na mensuração da ET e do ECC no controle do parâmetro de PC na produção e reprodução dos animais (ZARAGOZA, 2009). Embora o método de pesagem direta forneça a máxima precisão, esse manejo pode ser demorado e estressante para o animal, podendo causar ferimentos, já que os animais muitas vezes são conduzidos de modo forçado até a balança.

Nesse sentido, as mensurações realizadas por imagens digitais podem ser utilizadas não apenas em granjas de baixo nível tecnológico, em que muitas das vezes não possuem balanças e pequeno número de animais, mas também naquelas de alto nível tecnológico, as quais possuem balanças, mas precisam de funcionários disponíveis para a execução da pesagem, além de ser importante a preocupação, principalmente em fases de maternidade e gestação devido aos cuidados como a baixa movimentação das porcas até 35 dias após a IA, evitar o estresse dos animais. Além de possibilitar acompanhar a curva de crescimento, os fenótipos como comprimento, largura, altura e circunferência podem ser utilizados como bons preditores de desempenho dos animais (IGE et al., 2015; VAZ et al., 2016; YOSHIDA; KAWASUE, 2018).

Nos últimos anos, com o aprimoramento dos computadores, vem sendo possível utilizar imagens obtidas por câmeras e sensores de profundidade para a mensuração das medidas morfométricas de animais de diferentes espécies, reduzindo o estresse da coleta e possibilitando que um grande número de informações possa ser obtido em um período menor de tempo (FERNANDES; DÓREA; ROSA, 2020; CONDOTTA et al., 2020).

Entretanto, as equações de predição de PC a partir das medidas morfométricas devem ser frequentemente atualizadas, uma vez que com a seleção aplicada no melhoramento genético, as raças estrangeiras têm alterado sua conformação exterior, principalmente relacionados ao comprimento dorsal, altura, profundidade umbilical e largura peitoral em comparação aos

suínos trazidos ao Brasil e o início da utilização em cruzamentos nos anos de 1960, fazendo-se necessário novos estudos para a mensuração de medidas morfométricas atualizadas para a inserção em modelos matemáticos na predição do PC (ASABE, 1985; CONDOTTA et al., 2018).

### 3.3 O USO DE VISÃO COMPUTACIONAL PARA A PREDIÇÃO DO PESO CORPORAL

A visão computacional pode ser conceituada como o processo cognitivo da inteligência artificial aplicado como principal objetivo de simular a visão humana com uma imagem de entrada e a saída de informações na forma de conjunto de valores, que podem ou não formar outra imagem. Assim, inicia-se com a detecção e segmentação de bordas e, posteriormente, consiste na análise e processamento de imagens pelos programas computacionais, tendo (MARENGONI; STRINGHINI, 2009).

Com isto, define-se como visão computacional aplicada à biometria o campo que descreve a realidade por meio do reconhecimento padrão de impressões digitais, face, íris, espelho nasal e ruídos, interpretando, reconstruindo e extraíndo-as a partir de propriedades de acordo com as formas, texturas, densidades e distanciamentos, sendo essencialmente parte do desenvolvimento da inteligência artificial para lidar com questões visuais de interesse, por meio de técnicas de análise e processamento de imagens (AHRENDT; GREGERSEN; KARSTOFT, 2011).

Atualmente, buscando garantir o monitoramento preciso e contínuo de animais individuais ou grupos, têm-se visto a necessidade de tecnologias confiáveis e acessíveis para auxiliar no gerenciamento diário de tarefas em um conceito conhecido como zootecnia de precisão (SCHILLINGS; BENNETT; ROSE, 2021). Conforme observado por Nasirahmadi, Edwards e Sturm (2017), as técnicas de visão computacional baseadas em câmeras bidimensionais ou tridimensionais estão cada vez mais atualizadas e podem ser aplicadas, por exemplo, ao monitoramento da alimentação e comportamento em bovinos e suínos.

Na produção de suínos, principalmente quando se refere aos países desenvolvidos, novas tecnologias têm sido empregadas objetivando aferir e controlar diversas áreas desde o monitoramento do sistema respiratório, para o diagnóstico precoce de patologias, o uso de sistemas de câmeras acoplados a dispositivos de pesagens e a avaliação automatizada por meio de sensores eletrônicos. Os sensores normalmente funcionam como um sistema de detecção para que no momento os valores observados desviem de modo relevante dos esperados, os

mesmos emitam sinais de alerta instantaneamente, para que o responsável técnico ou produtor possam tomar uma ação imediata antes que a mudança detectada na resposta animal afete negativamente o seu desempenho (HARTUNG et al., 2017).

Recentemente, alguns sistemas estão sendo introduzidos para detecção automática do peso por meio da análise e processamento de imagens, o que acaba por tornar bastante prático a mensuração dessa característica nas propriedades. Contudo, essa predição é realizada com base em medidas morfométricas como comprimento do dorso e altura peitoral, frequentemente apontadas como importantes por estarem associadas ao peso por meio de modelos matemáticos, possibilitando o desenvolvimento de modelos que predizem o PC (GÓMEZ et al., 2021).

As câmeras comuns, bidimensionais (2D), podem ser utilizadas para a coleta de imagens e aplicadas ao monitoramento do PC, entretanto essas ferramentas não coletam imagens tridimensionais (3D). Assim, foi observado no sensor de profundidade uma possibilidade de combinações com opções para a captura de imagens a partir de vídeos, podendo serem retiradas por filtros em 3D ou em 2D, resultando em imagens com disparidade lateral e/ou dorsal (ZHU et al., 2015).

Estudo realizado por Pezzuolo et al. (2018) com o objetivo de relacionar o PC de suínos cruzados com medidas morfométricas obtidas por imagens digitais, capturadas pelo sensor Microsoft Kinect®, demonstrou um coeficiente de determinação ( $R^2$ ) entre a circunferência peitoral e comprimento dorsal com o PC de 93% e 84%, respectivamente. Os autores concluíram que o sensor além de baixo custo, possui extração com menor erro absoluto médio das medidas morfométricas para a predição do PC a partir da circunferência peitoral e comprimento dorsal baseado em modelos de regressão linear múltipla, com a diferença entre PC real e predito abaixo de 0,5 kg.

Estudo similar foi realizado por Sungirai, Masaka e Benhura (2014) em suínos das raças Landrace and LargeWhite e obtiveram valores de correlação de Pearson entre circunferência peitoral e comprimento dorsal com o PC de 97,7 e 94,4%, respectivamente e, o  $R^2$ , de 89,2% e 95,4% entre o PC com a circunferência peitoral e o comprimento dorsal, respectivamente.

Os autores Condotta et al. (2018) realizaram um trabalho com imagem digital advinda do sensor de profundidade capturando as áreas dorsais e laterais em suínos cruzados e as variáveis de comprimento dorsal, altura, profundidade e largura peitoral apresentaram o  $R^2$  com o PC de 95 %, 96%, 97% e 96%, respectivamente. Os modelos matemáticos a partir da análise de regressão linear com os coeficientes de determinação maiores do que 90% podem indicar que as variáveis estudadas explicam bem os valores de PC preditos a partir das imagens digitais.

### 3.4 MODELAGEM MATEMÁTICA PARA A PREDIÇÃO DE PESO CORPORAL

#### 3.4.1 Regressão Linear Múltipla (RLM)

Um dos fatores que afeta a precisão de predição de variáveis está relacionada com a abordagem estatística, tendo a RL como uma das alternativas de estimar parâmetros e, por meio da modelagem matemática, obter relação entre a variável resposta e as independentes, podendo ser considerada com uma das metodologias mais utilizadas dentre as demais técnicas estatísticas (MONTGOMERY; VINNING; PECK, 2001).

Um modelo de regressão linear que envolve mais de uma variável é chamado de modelo de RLM, podendo apresentar uma infinidade de parâmetros com funções lineares não conhecidas. Segundo Montgomery, Peck e Vining (2012), o modelo pode ser descrito pelo intercepto, os coeficientes de regressão estimados para cada variável explicativa e o erro ( $e$ ), como demonstrado na Equação (1) abaixo:

$$(1) y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + e,$$

O parâmetro  $\beta_0$  é o intercepto do plano de regressão, sendo a média da variável resposta ( $y$ ) quando as variáveis independentes apresentam valor igual a 0. Em geral, a variável resposta pode ser relacionada com as variáveis independentes ou preditoras, aonde os parâmetros  $\beta_j$ ,  $j = 0, 1, 2, \dots, k$ , são chamados de coeficientes de regressão e representam a mudança esperada na variável resposta por unidade alterada em  $X_j$  quando todas as demais variáveis independentes  $X_i$  ( $i \neq j$ ) são constantes (MRODE, 2014).

Um dos desafios para identificar modelos matemáticos adequados é a definição de quais são os preditores mais relevantes. Uma metodologia comumente utilizada para a seleção de variáveis é a RLM *stepwise*, isto é, realizada passo a passo, de modo que as variáveis explicativas são adicionadas ou retiradas do modelo com base em critérios pré-definidos como o fator de inflação de variância (VIF - *Variance Inflation Factor*), raiz do erro quadrático médio (RMSE - *Root Mean Squared Error*), critério de informação de Akaike (AIC - *Akaike Information Criteria*), entre outros (EFROYMSON, 1960; HOCKING, 1976; DRAPER; SMITH, 1981).

O RMSE é frequentemente utilizado para apresentar a precisão do modelo, já que seus valores representam o desvio médio entre a variável observada e a predita ao quadrado

(HYNDMAN; KOEHLER, 2006). Sendo assim valores de RMSE altos indicam baixa precisão do modelo de predição.

Já o VIF é bastante usado como um critério de diagnóstico da multicolinearidade (relação linear entre variáveis explicativas) e possibilita identificar quais variáveis preditoras devem ser removidas do modelo com o intuito de evitar a superestimação do  $R^2$ . De acordo com Daoud (2017), valores de VIF maiores do que 5 indicam variáveis altamente correlacionadas e, acima de 10, apontam que o  $R^2$  pode estar mal estimado devido à multicolinearidade. Do mesmo modo, Guirado (2019), ressalta que os critérios para seleção de modelos matemáticos, como o VIF, podem ser utilizados para verificar a qualidade da regressão, considerando que valores maiores que dez para este critério indicam claramente que a multicolinearidade está influenciando a estimação dos quadrados mínimos.

Segundo Konishi e Kitagawa (2008), o AIC é fundamentado na teoria da informação, isto é, oferece uma estimativa da informação relativa perdida quando um determinado modelo é usado para representar o processo que gerou os dados. Ao fazer isso, o AIC lida com a escolha entre a qualidade do ajuste do modelo e a complexidade do modelo sendo, geralmente, considerado o melhor critério quando a previsão é objetiva.

Por fim, o erro médio absoluto (MAE - *Mean Absolut Error*) pode ser considerado uma ferramenta de avaliação nas análises de modelos de regressão, isto é, a relação em um conjunto de testes em que a média dos valores absolutos dos erros de predição individuais é a diferença entre o valor verdadeiro e o valor predito para a variável dependente (WILLMOTT; MATSUURA; ROBESON, 2009; WILLMOTT; MATSUURA; ROBESON, 2005).

### **3.4.2 Regressão por Vetor de Suporte (SVR - *Support Vector Regression*)**

A regressão utilizando máquinas de vetor de suporte (SVM - *Support Vector Machine*) é uma metodologia de aprendizado de máquina (*Machine Learning*) bastante utilizada para classificação e regressão de dados (DENG; TIAN; ZHAN, 2012; TSANG; KWOK; ZURADA, 2005). O objetivo central do SVM é buscar um hiperplano de separação ótimo, maximizando a margem entre duas linhas paralelas, com suporte de hiperplanos e que apresenta boa capacidade de generalização.

A metodologia SVM está sendo utilizada com frequência e eficiência semelhantes à outras técnicas de aprendizado de máquinas como as Redes Neurais Artificiais (ANN), principalmente em situações que demandam classificação geral não linear, regressão e detecção



de valores discrepantes. Portanto, o SVM pode ser aplicado com sucesso a vários problemas práticos, como diagnóstico de falhas e predição de valores (MA et al., 2018).

Uma das principais diferenças entre o RLM e o SVR, é que este último possibilita maior flexibilidade para definir quanto de erro é aceitável no modelo, encontrando uma linha apropriada (ou hiperplano) para ajustar os dados. Em contraste com a minimização dos erros quadráticos utilizados na regressão linear, o objetivo do SVR é minimizar os coeficientes dos vetores (VAPNIK, 1998). Adicionalmente essa metodologia possibilita a otimização do algoritmo por meio da função *kernel* e dos hiperparâmetros utilizados no modelo (ALONSO; CASTÁNÓN; BAHAMONDE, 2013).

#### 4. METODOLOGIA

A pesquisa foi submetida à Comissão de Ética do Uso de Animais (CEUA) da Universidade Federal de Goiás (UFG), campus Samambaia, Goiânia, Goiás, Brasil, sob nº de aprovação 073/20.

##### 4.1 CARACTERIZAÇÃO DO LOCAL DE EXPERIMENTO E DOS ANIMAIS

A coleta de dados foi conduzida no setor de suinocultura do Instituto Federal de Educação, Ciência e Tecnologia Goiano (IF Goiano), campus Urutaí, Goiás, Brasil. Foram utilizados 52 suínos domésticos (*Sus scrofa domesticus*) cruzados, sendo 26 fêmeas e 26 machos, pesando entre 41 a 129 kg, média de 70 kg e desvio padrão em 22 kg. Os animais estavam na fase de terminação para, posteriormente, serem abatidos.

##### 4.2 COLETA DE DADOS

As coletas de dados ocorreram em outubro de 2021, no total de dois dias, realizadas pela manhã de 09h00 ao 11h30 e à tarde de 13h30 às 17h30. Observou-se que, no período de coleta entre 09h00 até 11h30, houve a presença de luminosidade dentro da instalação em que estavam sendo capturadas as imagens nos animais, fato que pode interferir na segmentação e detecção das bordas as quais delimitam as medidas morfométricas.

Os animais foram conduzidos até uma balança mecânica calibrada e com dimensionamento de 3 m<sup>2</sup>. Posteriormente, foram filmados pelo sensor com câmera de profundidade (Microsoft Kinect® v1), conforme a Figura 1. Para executar a gravação, foi

utilizado, primeiramente, o *software Kinect for Windows Developer Toolkit v.1.8.0*, na linguagem *Samples C++* com o filtro *Depth with Color-D3D* compilado ao *DirectX SDK*.



Figura 1 - Pesagem e filmagem dos animais.

Assim, com o sensor Kinect® conectado pelo cabo adaptador ao notebook com sistema Windows 64 bits e processador IntelCore® i5, utilizou-se o *software Kinect® Studio v.1.8.0* e, por meio das funções de “play” e “pause”, os vídeos foram gravados seguindo a sequência dos animais para a coleta de informações, sob formato “Color” (Figura 2). A câmera do sensor de profundidade Kinect® capturou 30 frames por segundo do tipo RGB com 640 x 800 pixels e estava em 1 m de distância com a balança mecânica.



Figura 2 - Imagem em RGB obtido a partir da gravação em "Color" pelo Kinect® Studio.

Posteriormente, os animais foram condicionados em um espaço separado com dimensionamento de 3 m<sup>2</sup> para a mensuração das medidas morfométricas por meio do hipômetro e fita métrica. Depois, obteve-se a retirada de fotografia RGB em 2D pela câmera do Iphone 11, da marca Apple®, com resolução de 1792 x 828 pixels, câmera dupla (ultra-angular e grande-angular) de 12 MP (Figura 3).



Figura 3 - Imagem RGB bidimensional obtida com telefone móvel.

O procedimento de captura das imagens foi realizado primeiramente pelo Kinect® com o animal ainda na balança, posteriormente o animal ficou posicionado e com o menor movimento possível e sem contenção, dada a espécie suína, para que a fotografia pelo telefone móvel pudesse ser retirada com a câmera posicionada em um ângulo de 90° com o piso e 1,4 m de distância do animal.

As mensurações das medidas morfométricas nos animais foram retiradas por apenas uma pessoa em todo o trabalho para que a subjetividade não interfira nos resultados. O Quadro 1 apresenta as descrições das medidas morfométricas coletadas de acordo com o posicionamento lateral ou dorsal nos animais (Figura 4; Figura 5).

Quadro 1 - Características morfométricas e ferramentas utilizadas para mensuração em suínos cruzados.

Medida	Descrição	Material
<b>Mensurações manuais</b>		
Comp. Dorsal (CD)	Linha reta do ponto médio entre as orelhas à base da cauda	Fita métrica
Circunf. Peitoral (CP)	Região distal da escápula e tríceps do braço	Fita métrica
Circunf. Flanco (CF)	Região no oblíquo externo do abdômen	Fita métrica
Larg. Peitoral (LP)	Distância em linha reta horizontal transversal na escápula	Hipômetro
Larg. Flanco (LF)	Distância de 6,5 cm da linha média dorsal posterior a última costela (P2)	Hipômetro
Alt. Peitoral (AP)	Distância lateral entre o ponto mais alto do ombro ao solo	Hipômetro
Alt. Flanco (AF)	Distância lateral entre o ponto P2 ao solo	Hipômetro
Profundidade (P)	Distância entre o dorso e a lateral umbilical	Hipômetro

<b>Medidas a partir das imagens dorsais</b>		
Comp. Dorsal (CD)	Linha reta do ponto médio entre as orelhas à base da cauda	Sensor de profundidade
Larg. Peitoral (LP)	Distância em linha reta horizontal transversal na escápula	Sensor de profundidade
Larg. Flanco (LF)	Distância de 6,5 cm da linha média dorsal posterior a última costela (P2)	Sensor de profundidade
Larg. Abdominal (LA)	Distância entre o lado direito e esquerdo na região abdominal	Sensor de profundidade
Área Dorsal (AD)	Extensão que compreende toda a região dorsal	Sensor de profundidade
Per. Dorsal (PD)	Extensão da linha de contorno da área dorsal	Sensor de profundidade
<b>Medidas a partir das imagens laterais</b>		
Comp. Lateral (CL)	Linha reta do ponto médio da orelha até o fim da extensão do corpo	Telefone móvel
Alt. Peitoral (AP)	Distância lateral entre o ponto mais alto do ombro ao solo	Telefone móvel
Alt. Flanco (AF)	Distância lateral entre o ponto P2 ao solo	Telefone móvel
Profundidade (P)	Distância entre o dorso e a lateral umbilical	Telefone móvel
Área Lateral (AL)	Extensão que compreende toda a região lateral	Telefone móvel
Per. Lateral (PL)	Extensão da linha de contorno da área lateral	Telefone móvel

Comp.= Comprimento; Circunf. = Circunferência; Larg.=Largura; Alt. = Altura; Per = Perímetro. Todas as características foram mensuradas em centímetros.




Figura 4 - Esquemática das medidas morfológicas de CD, AP, AF, CP, CF e P.

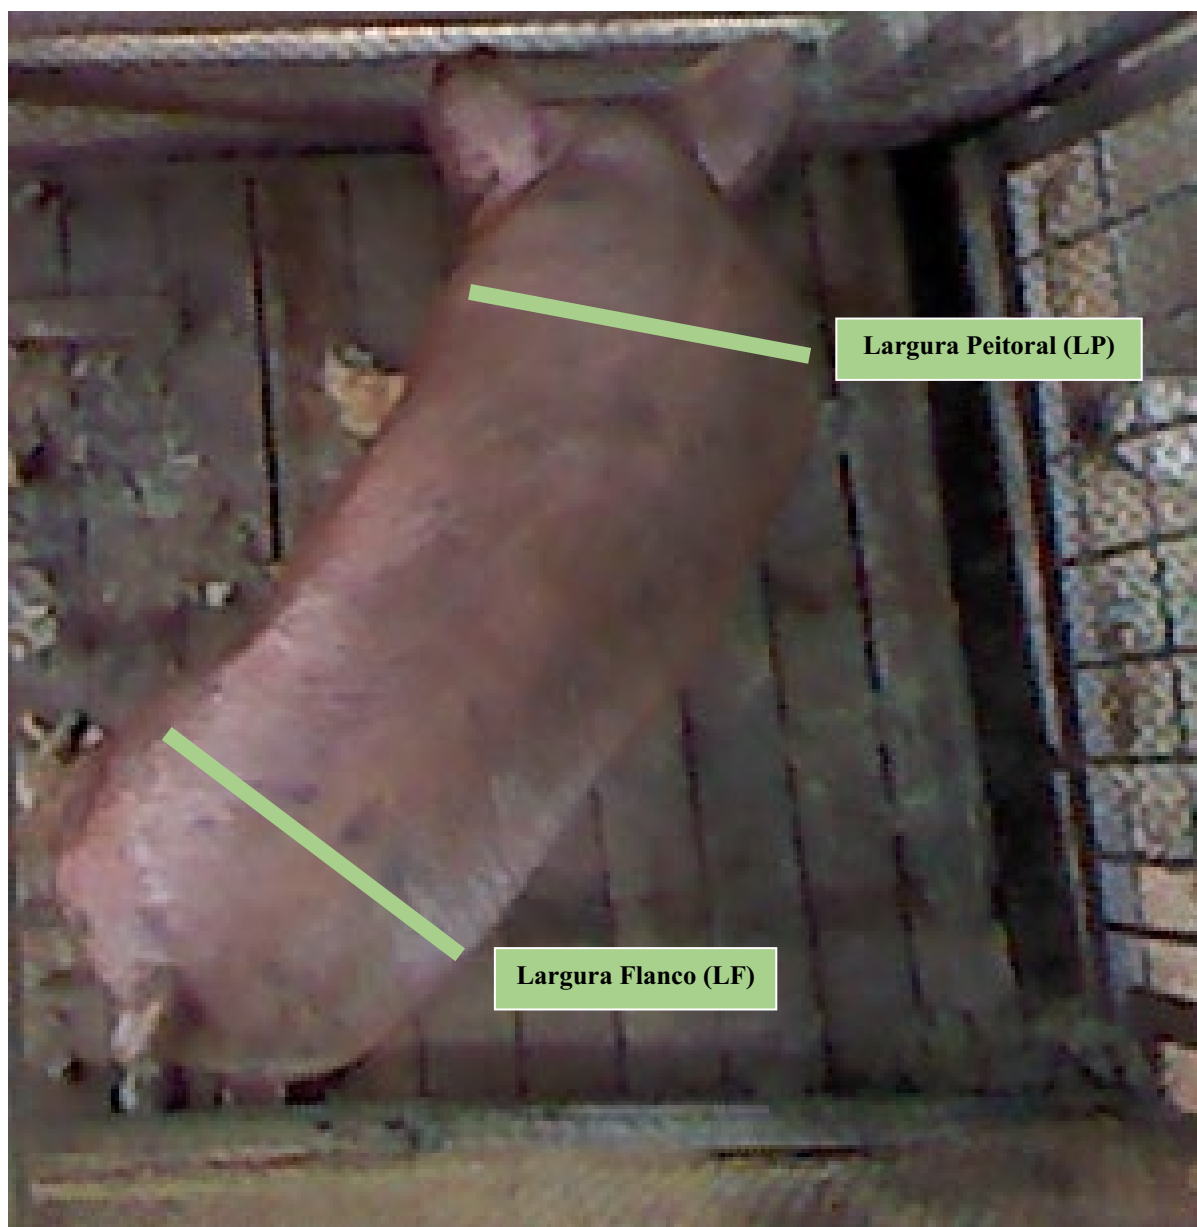


Figura 5 - Esquematização das medidas morfométricas reais de LP e LF realizadas em suínos cruzados.

#### 4.3 ANÁLISE E PROCESSAMENTO DAS IMAGENS

Todas as imagens foram processadas pelo *software* ImageJ2 versão 1.53k, sem a realização de nenhum processamento prévio ou edições anteriores, apenas pela seleção manual dos frames. Primeiramente, o ImageJ2 foi calibrado por imagens digitais com medida linear real de 1 cm considerando a equivalência igual à 88027 pixels (Figura 6).

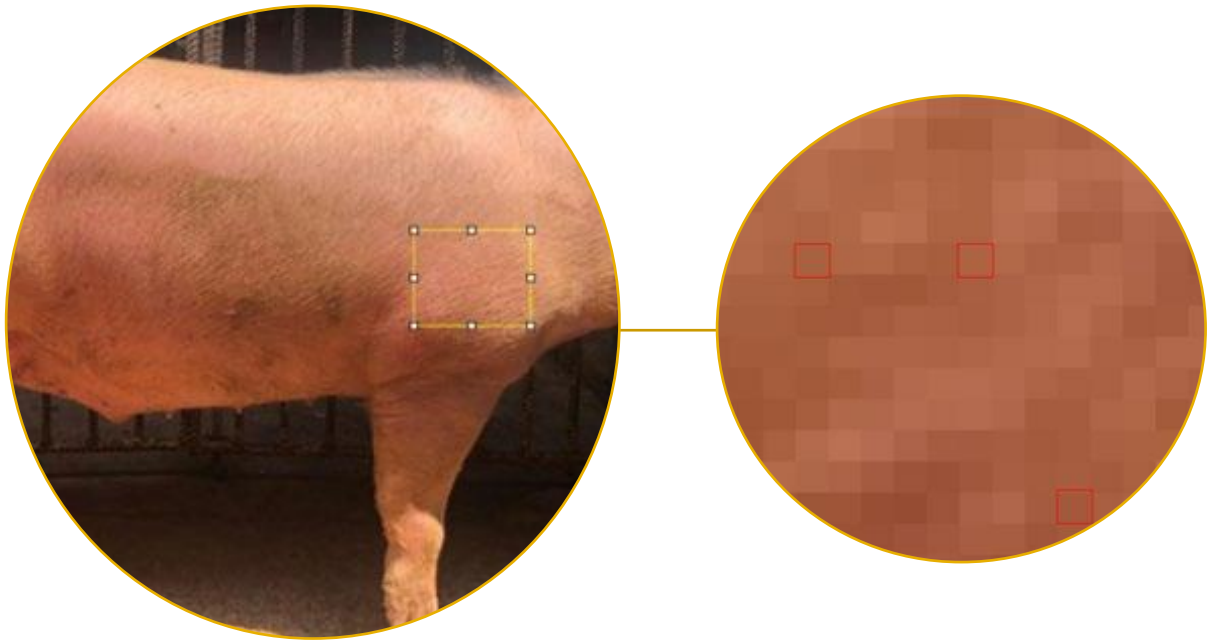


Figura 6 - Contagem de pixels e conversão pela equivalência de 88027 *pixels* para 1 *cm real*.

Após todas as imagens passarem pela seleção, aquelas capturadas pelo telefone móvel foram convertidas para *RGB Stack* e os frames transformados em máscara (*mask*) para a contagem dos pixels (Tabela 8; Tabela 9). Com relação à análise das imagens dorsais, selecionou-se a partir da gravação dos vídeos pelo Kinect® manualmente em 42944 frames. Assim, seguiu-se os critérios de exclusão como o posicionamento dos animais nas imagens, não aparecimento do corpo inteiro e a má iluminação devido ao reflexo solar no local de coleta, foi escolhido o melhor frame para o processamento totalizando 52 frames, considerando um frame por animal, sendo processadas com traços do tipo “*freehand*” (Figura 7; Figura 8).

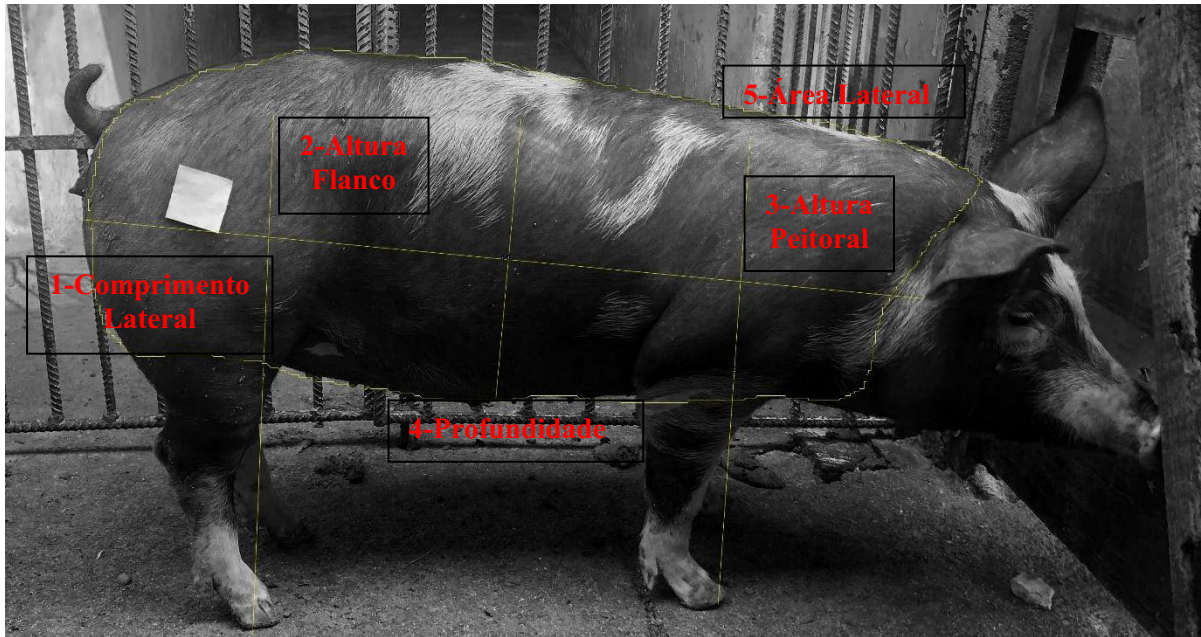


Figura 7 - Processamento da imagem lateral no ImageJ2.




Figura 8 - Processamento da máscara retirada do frame dorsal no ImageJ2.

#### 4.4 ANÁLISE ESTATÍSTICA

##### 4.4.1 Análise de consistência e descritiva dos dados



A edição, consistência e análise descritiva dos dados foram realizadas e consideradas apenas as observações no intervalo de  $\pm 3,5$  desvios-padrões da média de cada variável. As correlações de Pearson entre as variáveis morfométricas e o PC foram realizadas utilizando o pacote “Hmisc” (HARRELL JR; DUPONT, 2021) do programa R, versão 4.0.3.10 (R Development Core Team, 2020).

#### 4.4.2 Elaboração dos modelos matemáticos de predição

Os modelos matemáticos foram elaborados pelas metodologias RLM e SVR para a predição do PC, com base nos seguintes bancos de dados: a) mensurações morfométricas reais; b) mensurações morfométricas obtidas a partir de imagens digitais laterais; c) mensurações morfométricas obtidas a partir de imagens digitais dorsais; d) mensurações morfométricas obtidas a partir de imagens digitais laterais e dorsais dos animais.

##### 4.4.2.1 Modelo de Regressão Linear Múltipla

A predição do PC com base nas mensurações morfométricas foi realizada pelos métodos de regressão linear múltipla *stepwise* reverso e o primeiro modelo testado incluiu todas as variáveis independentes que apresentaram os valores de VIF inferiores à 10 (HAIR JR, 2005). As estimativas e o valores de VIF dos modelos completos estão apresentados no Anexo A (Tabelas 10 a 13). A seleção de variáveis pelo método *stepwise* foi realizado pelo AIC. Sendo assim, foi selecionado o modelo que apresentou menor AIC médio dentre os avaliados pelo *stepwise*.

O modelo utilizado para a regressão linear múltipla foi por meio da Equação (2):

$$(2) Y = \beta_0 + \beta_1x_1 + \dots + \beta_ix_i + \varepsilon,$$

em que Y representa a variável resposta,  $\beta_ix_i$  representam as variáveis explicativas e  $\varepsilon$  representa o erro experimental.

Os modelos selecionados pelo método *stepwise* e foram submetidos à análise de variância e as variáveis explicativas que apresentaram valor de significância (P-valor) menores do que 0,05 foram incluídas no modelo selecionado final. Os modelos foram avaliados pelo  $R^2$ ,  $R^2$  ajustado e coeficiente de determinação ajustado, RSME e MAE.

Para estimar a capacidade preditiva do modelo, a equação composta pelas variáveis significativas na análise de regressão múltipla foi reavaliada no mesmo banco de dados, por validação cruzada (*holdout*), na qual 70% dos dados foi considerado população de treinamento e 30% de teste.

Todos os procedimentos realizados na análise de regressão linear múltipla foram realizados com os pacotes “car” (FOX; WEISBERG, 2019), “tidyverse” (WICKHAM et al., 2019) e “caret” (KUHN et al., 2021) do programa computacional R, versão 4.0.3.10 (R Development Core Team, 2020).

#### 4.4.2.2 Regressão por Máquina de Vetor de Suporte

A seleção das variáveis do modelo pela regressão por máquina de vetor de suporte, foi realizado pelo algoritmo SVM-RFE proposto por Guyon et al. (2002). O algoritmo objetiva encontrar um subconjunto de variáveis que maximiza o desempenho dos preditores, de modo que o modelo mais adequado é selecionado. Assim como o *stepwise* reverso, esse método faz uma seleção sequencial reversa, de modo que é testado inicialmente o modelo com todas as variáveis, sendo retiradas uma variável a cada iteração, até que o subconjunto de variáveis seja selecionado. As variáveis removidas são aquelas que minimizam a variação dos pesos quadráticos das variáveis.

Após a seleção das variáveis, foi utilizado um algoritmo de *grid search* (GUYON, 2002) para otimizar os hiperparâmetros do modelo SVR. Basicamente, o algoritmo testa todas as combinações possíveis de hiperparâmetros, selecionando aqueles que obtiveram o menor erro.

O modelo selecionado foi avaliado pelo  $R^2$ , RMSE e MAE após a validação realizada utilizando 70% dos dados como população de treinamento e 30% como população de teste. Para a elaboração dos modelos a partir do SVR foram utilizados os pacotes “caret” (KUHN et al., 2021), “mlbench” (LEISCH; DIMITRIADOU, 2021) e “e1071” (MEYER et al., 2021) do programa computacional R, versão 4.0.3.10 (R Development Core Team, 2020).

#### 4.4.2 Validação dos modelos selecionados

Após a identificação dos modelos mais adequado para prever o PC a partir dos diferentes bancos de dados, foi estimado o peso médio predito por cada uma das equações selecionadas pelo método RLM e SVR, que foi comparado com o peso médio real, proveniente da balança para verificar o erro de predição em kg.

## 5. RESULTADOS E DISCUSSÃO

As Tabelas 1, 2 e 3 apresentam a estatística descritiva das medidas morfométricas reais e das imagens laterais e dorsais.

Tabela 1 - Estatística descritiva das variáveis reais de PC (kg) e das medidas morfométricas reais (cm).

	<b>PC</b>	<b>CD</b>	<b>CP</b>	<b>CF</b>	<b>LP</b>	<b>LF</b>	<b>AP</b>	<b>AF</b>	<b>P</b>
<b>Média</b>	70,92	100,37	96,1	97,98	26,9	26,54	52,38	58,73	30,65
<b>DP</b>	22,72	10,72	11,52	11,78	3,59	3,41	6,86	7,71	4,12
<b>Mínimo</b>	41	80	79	80	21	20	41	38	23
<b>Máximo</b>	129	125	126	125	37	35	67	73	39
<b>CV (%)</b>	32,04	10,68	11,99	12,02	13,36	12,85	13,1	13,13	13,43

DP = Desvio Padrão; CV = Coeficiente de Variação; CD = Comprimento Dorsal; CP = Circunferência Peitoral; CF = Circunferência Flanco; LP = Largura Peitoral; LF = Largura Flanco; AP = Altura Peitoral; AF = Altura Flanco; P = Profundidade.

Tabela 2 - Estatística descritiva das medidas morfométricas a partir das imagens laterais (cm)\*.

	<b>CL</b>	<b>AP</b>	<b>AF</b>	<b>P</b>	<b>AL</b>	<b>PL</b>
<b>Média</b>	99,28	58,69	66,28	34,76	3045,39	252,11
<b>DP</b>	12,83	8,47	10,70	5,86	748,41	31,63
<b>Mínimo</b>	60,32	33,29	41,12	23,06	1260,98	156,77
<b>Máximo</b>	127,23	80,54	92,81	49,30	4737,18	319,22
<b>CV (%)</b>	12,92	14,43	16,14	16,86	24,58	12,55

CL = Comprimento Lateral; AP = Altura Peitoral; AF = Altura Flanco; P = Profundidade; AL = Área Lateral; PL = Perímetro Lateral. \*imagens mensuradas previamente em pixels e convertidas em centímetros (1 cm = 88027 pixels).

Tabela 3 - Estatística descritiva das medidas morfométricas retiradas das imagens dorsais (cm)\*\*.

	<b>CD</b>	<b>LP</b>	<b>LF</b>	<b>LA</b>	<b>AD</b>	<b>PD</b>
<b>Média</b>	121,89	37,25	37,60	37,69	360,13	296,84
<b>DP</b>	15,79	6,80	7,32	6,51	107,75	39,61
<b>Mínimo</b>	90,88	23,74	26,24	28,06	210,16	224,93
<b>Máximo</b>	154,50	55,10	56,91	55,21	637,30	385,11
<b>CV (%)</b>	12,96	18,27	19,46	17,28	29,92	13,35

CD = Comprimento Dorsal; LP = Largura Peitoral; LF = Largura Flanco; LA = Largura Abdominal. AD = Área Dorsal; PD = Perímetro Dorsal. \*\* imagens mensuradas previamente em pixels e convertidas em centímetros (1 cm = 88027 pixels).

Uma das razões que pode ter afetado o coeficiente de variação (CV) da característica PC para os dados reais seria o fato de que o experimento foi realizado com animais cruzados, de diferentes sexos o que gerou grande amplitude no peso dos animais avaliados (entre 41 a 129 kg), apesar das medidas não terem sido consideradas como *outliers*. Entretanto, trabalhos sugerem que subdivisão em grupos mais homogêneos quanto ao PC poderia ser mais adequado e fornecer maior precisão dos dados, impactando em menores CV (FERNANDES et al., 2019; KASHIHA et al., 2014).

De acordo com Fernandes et al. (2019) e Kashiha et al. (2014), a subdivisão dos animais em categorias de PC deve ser realizada em grupos de animais até 30 kg, na fase de creche, de 30 até 70 kg, na fase de crescimento e, acima de 70 kg, na fase de terminação. Entretanto, a subdivisão dos animais não foi realizada no presente estudo devido ao pequeno número amostral em cada intervalo de PC, o que resultaria em menor precisão nos modelos matemáticos.

Segundo Mukaka (2012), correlações lineares de Pearson podem ser classificadas como fraca quando os valores apontarem de 30% a 50%, correlação moderada quando estiverem de 50% a 70% e, acima de 70%, indica uma correlação forte. Todas as correlações lineares de Pearson entre o PC real e as características morfométricas foram positivas de magnitude moderada à alta e significativas (Tabela 4). As variáveis que mais tiveram correlações com o PC foram a circunferência peitoral (97%) e do flanco (95%), altura peitoral (93%) e profundidade (90%), apesar de todas as demais variáveis mensuradas apresentaram valores altos e próximos entre si.

Tabela 4 - Correlação linear de Pearson (acima da diagonal) e valores de significância (abaixo da diagonal) entre o PC real e as medidas morfométricas reais.

	<b>CD</b>	<b>CP</b>	<b>CF</b>	<b>LP</b>	<b>LF</b>	<b>AP</b>	<b>AF</b>	<b>P</b>
<b>PC</b>	0,85	0,97	0,95	0,89	0,87	0,93	0,71	0,90
<b>CD</b>	1,00	0,82	0,80	0,76	0,72	0,80	0,69	0,82
<b>CP</b>	<0,001	1,00	0,97	0,88	0,85	0,91	0,65	0,89
<b>CF</b>	<0,001	<0,001	1,00	0,89	0,86	0,89	0,65	0,87
<b>LP</b>	<0,001	<0,001	<0,001	1,00	0,88	0,84	0,57	0,83
<b>LF</b>	<0,001	<0,001	<0,001	<0,001	1,00	0,84	0,62	0,81
<b>AP</b>	<0,001	<0,001	<0,001	<0,001	<0,001	1,00	0,72	0,87
<b>AF</b>	<0,001	<0,001	<0,001	<0,001	<0,001	<0,001	1,00	0,68
<b>P</b>	<0,001	<0,001	<0,001	<0,001	<0,001	<0,001	<0,001	1,00

CD = Comprimento Dorsal; CP = Circunferência Peitoral; CF = Circunferência Flanco; LP = Largura Peitoral; LF = Largura Flanco; AP = Altura Peitoral; AF = Altura Flanco; P = Profundidade.

Os resultados foram similares aos de Banik et al. (2012), que encontraram correlações altas entre o PC com as medidas morfométricas de circunferência peitoral, profundidade e comprimento dorsal de 90%, 89% e 91%, respectivamente. Kumari et al. (2020) buscando correlacionar medidas morfométricas com o PC utilizando 39 suínos machos e fêmeas e obtiveram valores de 89% e 76% entre o PC e a circunferência peitoral e comprimento dorsal.

O comprimento dorsal foi a medida morfométrica mais citada na literatura devido sua alta correlação e  $R^2$  acima de 90% quando utilizado na predição do PC, seguido da circunferência peitoral e a média das alturas peitoral e no flanco (PEZZUOLO et al., 2018; SUNGIRAI; MASAKA; BENHURA, 2014; FERNANDES et al., 2019). Ainda, segundo a Tabela 4, as medidas morfométricas de profundidade e altura peitoral estão altamente correlacionadas com as demais ( $r > 0,80$ ) e, além disso, possuem alta correlação linear entre si, isto é, a inserção das duas características em modelos de predição podem gerar multicolinearidade.

A Tabela 5 apresenta as correlações moderadas entre todas as medidas morfométricas preditas com imagens digitais laterais e o PC, o que indica que mesmo sendo preditos indiretamente, pela conversão de pixels das imagens para cm, a correlação entre a variável PC e as demais (preditas) continuam apresentando correlação moderada à alta.

Tabela 5 - Correlação linear de Pearson (acima da diagonal) e valores de significância (abaixo da diagonal) entre o PC real e as medidas morfométricas preditas pelas imagens laterais.

	<b>CL</b>	<b>AP</b>	<b>AF</b>	<b>P</b>	<b>AL</b>	<b>PL</b>
<b>PC</b>	0,50	0,49	0,58	0,61	0,66	0,58
<b>CL</b>	1,00	0,80	0,76	0,74	0,94	0,98
<b>AP</b>	<0,001	1,00	0,73	0,82	0,80	0,83
<b>AF</b>	<0,001	<0,001	1,00	0,89	0,85	0,82
<b>P</b>	<0,001	<0,001	<0,001	1,00	0,83	0,80
<b>AL</b>	<0,001	<0,001	<0,001	<0,001	1,00	0,98
<b>PL</b>	<0,001	<0,001	<0,001	<0,001	<0,001	1,00

CL = Comprimento Lateral; AP = Altura Peitoral; AF = Altura Flanco; P = Profundidade; AL = Área Lateral; PL = Perímetro Lateral. \*Capturadas pelo telefone móvel.

Quanto às medidas morfométricas retiradas das imagens dorsais (Tabela 6), observa-se a existência de alta correlação entre o comprimento do dorso e as medidas de largura peitoral (89%), do flanco (86%) e abdominal (84%), além da área dorsal (82%) e perímetro dorsal (93%), bem como também houve alta correlação entre estas medidas e o perímetro do dorso.

Yu, Lee e Morota (2021) estudando o desenvolvimento de modelos matemáticos para a predição de PC por meio de medidas morfométricas manuais e preditas por imagens dorsais encontraram altas correlações de Pearson entre o PC real com as mensurações de comprimento dorsal (89%), largura (83%), altura (70%) e volume calculado a partir das três medidas (90%), semelhante ao presente estudo, uma vez que em outros estudos o volume foi calculado a partir da área dorsal em pixels (KASHIHA et al., 2014; YU; LEE; MOROTA, 2021).

Da mesma forma que as medidas morfométricas reais, as preditas pelas imagens dorsais também apresentaram correlações altas, acima de 82%, principalmente aquelas em comum entre as reais e pela imagem lateral, como o comprimento dorsal (85% e 89%, respectivamente) e a largura peitoral (89% e 86%, respectivamente), o que demonstra que mesmo sendo mensuradas a partir de imagens digitais, essas medidas continuam a apresentar alta correlação com o PC.

Tabela 6 - Correlação linear de Pearson entre o PC real (acima da diagonal) e valores de significância (abaixo da diagonal) e as medidas morfométricas previstas pelas imagens dorsais\*\*.

	<b>CD</b>	<b>LP</b>	<b>LF</b>	<b>LA</b>	<b>AD</b>	<b>PD</b>
<b>PC</b>	0,89	0,86	0,84	0,82	0,93	0,92
<b>CD</b>	1,00	0,81	0,75	0,72	0,90	0,97
<b>LP</b>	<0,001	1,00	0,85	0,80	0,90	0,87
<b>LF</b>	<0,001	<0,001	1,00	0,92	0,94	0,83
<b>LA</b>	<0,001	<0,001	<0,001	1,00	0,91	0,81
<b>AD</b>	<0,001	<0,001	<0,001	<0,001	1,00	0,95
<b>PD</b>	<0,001	<0,001	<0,001	<0,001	<0,001	1,00

CD = Comprimento Dorsal; LP = Largura Peitoral; LF = Largura Flanco; LA = Largura Abdominal. AD = Área Dorsal; PD = Perímetro Dorsal. \*\*Capturadas pelo Kinect®.

Pezzuolo et al. (2018) avaliando a eficiência do uso do sensor de profundidade para prever o peso corporal por meio da mensuração de medidas morfométricas em suínos entre 6 e 46 kg, observaram que as medidas morfométricas previstas pelas imagens digitais tiveram altas correlações com as mensurações manuais, sendo de 77% para altura peitoral e 93% para circunferência peitoral.

A Tabela 7 apresenta as variáveis e os parâmetros dos modelos selecionados para a predição do PC pela metodologia RLM e SVR a partir de medidas morfométricas reais e obtidas por imagens digitais (lateral, dorsal e lateral-dorsal) e os valores de  $R^2$ , RMSE, MAE e o EPR, representando a diferença em kg entre o PC predito e o real.

O modelo matemático selecionado para predição do PC a partir das mensurações reais pela metodologia RLM (Tabela 7; Equação 3) demonstrou que a variável resposta pode ser prevista pelas variáveis sexo e as medidas morfométricas de comprimento dorsal, largura e altura peitoral. Assim, a partir das mensurações reais, pode-se constatar que o aumento em 1 cm nas variáveis comprimento dorsal, largura peitoral e altura peitoral dos animais impacta diretamente em aumento de 320 g, 1,19 kg e 1,28 kg, respectivamente, na média do PC dos suínos cruzados.

Sungirai, Masaka e Benhura (2014) tiveram como resultado a partir de medidas morfométricas reais que a cada 1 cm a mais no comprimento dorsal, o PC é aumentado em 1,18 kg em suínos cruzados na fase de terminação. Ainda, em Pezzuolo et al. (2018), a modelagem matemática RLM demonstrou que para o aumento de 1 cm no comprimento dorsal mensurado, real e o predito pelo sensor de profundidade, o PC aumenta em 409 g e 380 g, respectivamente, em suínos na fase de crescimento e terminação.

No modelo matemático com as medidas morfométricas reais, o valor do  $R^2$  que explicou o PC pelo RLM e SRV (Tabela 7; Equação 3; Equação 4) foram bem próximos, de 95% e 99%, respectivamente, tendo o comprimento dorsal, largura e altura peitoral como medidas em comum.

A diferença entre o PC real e o predito pelo SVR e RLM por meio das mensurações reais foi de - 400 g e - 1,95 kg, respectivamente (Tabela 7; Equação 3; Equação 4). Essa diferença encontrada entre metodologias pode ser explicada pelo modo de como as variáveis são selecionadas estatisticamente e a entrada/saída de cada uma delas por meio da regressão de vetores de suporte e análise de regressão linear, sendo considerado os valores de  $R^2$  e  $VIF < 10$  seguido do método *stepwise* (AIC), respectivamente. Por isto, as variáveis predictoras do PC não são as mesmas entre os modelos selecionados, bem como os erros de predição também são diferentes.

A Equação 5 (Tabela 7) apresenta a medida morfométrica de profundidade mensurada a partir da imagem lateral do animal como a única preditora do PC, considerando que o aumento em 1 cm ocasiona aumento discreto, porém significativo ( $P < 0,05$ ) na variável resposta. Já a Equação 6 (Tabela 7) aponta as medidas morfométricas largura peitoral e flanco ( $R^2=49\%$ ), apresentando menores erros do que o modelo que inclui apenas profundidade ( $R^2=40\%$ ) para predizer o PC, por meio do RLM.

Da mesma forma que a predição de PC pelas imagens laterais discutidas acima (Tabela 7; Equação 5; Equação 6), quando as imagens foram capturadas dorsalmente, a inclusão das variáveis da largura e do fator sexo sob a predição do PC também não tiveram aumentos consideráveis sob a variável dependente, mas foram significativas (Tabela 7; Equação 7; Equação 8). O impacto do sexo dos animais na predição do PC é esperado pois, de modo geral, machos tendem a ser mais pesados do que fêmeas quando animais da mesma idade são comparados.

As imagens laterais e dorsais (Tabela 7; Equação 9) quando combinadas no modelo RLM apresentam as variáveis predictoras profundidade e largura peitoral. A profundidade e a largura peitoral, apesar de valores pequenos, apresentam influência significativa ao PC real quando aumentadas em 1 cm, o que ressalta a importância da seleção fenotípica de animais mais largos na cavidade torácica e com maior profundidade.

Por último, quando combinadas as medidas morfométricas preditas por ambas imagens laterais e dorsais, a quantidade de variáveis predictoras pela análise SVR foi superior aos demais modelos matemáticos (Tabela 7; Equação 10). Contudo, esse modelo mais completo pode ser considerado como o mais próximo do PC predito com as mensurações reais, pelo fato de incluir



mais informações de medidas dos animais e, quando comparado com a análise RLM, explicam 10% a mais da variância do PC.

O melhor modelo a partir da análise RLM e mais próximo ao real foi o obtido pelas medidas morfométricas das imagens dorsais (Tabela 7; Equação 7), sendo estas explicando 91% da variância do PC predito e com 3,83 kg acima do real. Quanto à análise por SVR, o melhor modelo de predição do PC foi o combinado de imagens dorsais e laterais (Tabela 7; Equação 10), com 98% das medidas morfométricas explicando a variância do PC predito.

Entretanto, apesar de o melhor modelo de predição apontado pelo estudo ser o que combina as imagens laterais e dorsais, o modelo com imagens dorsais pelo método SVR demonstrou alta eficiência ( $R^2 = 91\%$ ) e maior praticidade de uso, já que possibilita a coleta de dados de modo sistematizado, apresentando potencial para ser utilizado em animais agrupados em lotes com maior facilidade.

Tabela 7 - Modelos seleccionados para a predição do PC a partir da modelagem matemática RLM e SVR.

Coleta	Equação	Modelagem	Modelo Seleccionado	R <sup>2</sup>	RMSE	MAE	EPR
<b>Real</b>	(3)	RLM	$PC = -110,05 + 4,38 \text{ Sexo} + 0,32 \text{ CD} + 1,19 \text{ LP} + 1,28 \text{ AP}$	0,95	6,78	4,84	- 1,95
	(4)	SVR	$PC = 0,38 + 9,12 \text{ CD} + 12,89 \text{ CP} + 9,03 \text{ CF} + 8,13 \text{ LP} + 7,79 \text{ LF}$ $+ 7,31 \text{ AP} + 7,03 \text{ AF} + 9,18 \text{ P}$	0,99	0,25	0,07	- 0,40
<b>Imagem lateral*</b>	(5)	RLM	$PC = -10,06 + < 0,00125 \text{ P}$	0,40	13,57	11,95	+ 5,66
	(6)	SVR	$PC = 8,78 \text{ AP} + 6,89 \text{ AF}$	0,49	11,88	9,85	+ 4,20
<b>Imagem dorsal**</b>	(7)	RLM	$PC = -46,77 + 6,25 \text{ Sexo} + 0,0019 \text{ LP} + 0,00015 \text{ LA}$	0,91	7,45	6,28	+ 3,82
	(8)	SVR	$PC = 0,23 + 8,25 \text{ LP} + 8,03 \text{ AD} + 6,50 \text{ CD}$	0,86	7,29	6	+ 2,10
<b>Imagem lateral-dorsal</b>	(9)	RLM	$PC = -56,25 + < 0,00112 \text{ P} + < 0,00027 \text{ LP}$	0,88	8,20	7,08	+ 3,84
	(10)	SVR	$PC = 0,27 + 7,59 \text{ CL} + 12,08 \text{ LP} + 8,01 \text{ LF} + 9,56 \text{ LA}$ $+ 10,50 \text{ AD} + 11,16 \text{ PD} + 7,52 \text{ AP} + 8,36 \text{ AF}$ $+ 7,28 \text{ P} + 6,42 \text{ AL} + 5,95 \text{ PL} + 10,54 \text{ CD}$	0,98	2,84	2,33	- 0,80

CD = Comprimento Dorsal; CP = Circunferência Peitoral; CF = Circunferência Flanco; LP = Largura Peitoral; LF = Largura Flanco; AP = Altura Peitoral; AF = Altura Flanco; P = Profundidade; CL = Comprimento Lateral; P = Profundidade; AL = Área Lateral; PL = Perímetro Lateral; LA = Largura Abdominal; AD = Área Dorsal; PD = Perímetro Dorsal; EPR = Erro entre Predito-Real (kg). \*Capturadas pelo telefone móvel. \*\*Capturadas pelo Kinect®.

Os resultados apontam que a seleção fenotípica para animais mais largos e altos na região peitoral podem trazer maior produtividade pelo aumento do PA em cevados terminados. Entretanto, deve ser avaliado o impacto na lucratividade da propriedade, já que animais de maior porte apresentam maiores exigências nutricionais de manutenção, o que pode onerar o sistema produtivo. Ademais, as características que explicam maior proporção da variância do PC encontram-se na parte anterior do animal (peitoral), aonde se localizam os cortes menos nobres.

Fernandes et al. (2019) utilizaram imagens digitais para a predição de peso corporal utilizando a coleta de fenótipos em suínos e relataram maior facilidade e praticidade, além da redução de trabalhos manuais, mostrando a possibilidade de alcançarem alta precisão de predição apenas com a informação dos animais aos sistemas de visão computacional. Kongsro (2014) demonstrou a aplicação de câmeras do sensor de profundidade para a estimativa do PC em suínos na fase de crescimento e terminação com um RMSE relatado de 4,8% (3,38 kg) e um  $R^2$  de 0,99 para 71 animais com a amplitude em 30 a 140 kg.

Condotta et al. (2018) estudaram imagens laterais e dorsais capturadas pela câmera do sensor de profundidade por meio das medidas de LF, CD e volume calculado pela área dorsal em pixels. Os autores concluíram que a correlação entre o PC e o volume foi significativa e alta (97%) e, além disso, indicaram que 99,07% da variabilidade do PC dos animais alojados nas fases de crescimento e terminação pode ser explicado pelo volume obtido por meio dos dados fornecidos no sensor de profundidade da Microsoft Kinect®, resultando em erro de predição em 3,13 kg superior em comparação ao PC real.

Ainda, estudos recentes utilizando a modelagem matemática por meio de aprendizado de máquina para a predição de peso corporal pelas medidas morfométricas extraídas de imagens digitais como a área, perímetro e comprimento dorsal, verificaram erro de predição em 3% (JUN et al., 2018; CANG; HE; QIAO, 2019). Contudo, requerem uma seleção de um grande número de imagens para que o algoritmo realize a detecção das bordas, segmentação e predição dos valores das medidas morfométricas e às correlacione com o peso corporal (WANG et al., 2008; WONGSRIWORAPHON et al., 2012).

Dentre os principais fatores que podem estar associados aos erros entre o PC real e o predito estão a falta de medidas computadorizadas da cabeça e membros, heterogeneidade e grande amplitude de PC, posicionamento do animal durante a coleta de dados, principalmente ao mensurar o comprimento dorsal e sua importância destacada ao longo do presente estudo pela correlação ao PC, além disso, ao fato da segmentação e detecção de bordas dos animais

nas imagens digitais ter sido realizada no modo "*freehand*", o que pode ocasionar sub ou superestimação dos pixels dentre as medidas morfométricas.

Os modelos elaborados a partir de imagens digitais capturadas a partir da câmera do sensor de profundidade e pelo telefone móvel, neste estudo, mostrou-se grande potencial para implementação em larga escala de modo automatizado, substituindo as mensurações de peso com a balança.

Estudos realizados para predição de PC, devido a importância dessa característica na lucratividade da atividade, devem ser ampliados incluindo mais animais e abrangendo diferentes fases de produção e raças para que sejam utilizados de modo acurado na cadeia suinícola.

## 6. CONCLUSÃO

Os modelos matemáticos desenvolvidos a partir das medidas morfométricas preditas pelas imagens digitais provaram ter potencial para estimar o PC de suínos cruzados utilizando-se medidas morfométricas como o comprimento dorsal, profundidade e largura peitoral. Dentre os modelos que utilizaram imagens digitais, a combinação das imagens laterais e dorsais apresentaram erro de 800 gramas a menos quando comparado com os valores reais, sendo considerado o modelo mais adequado para a predição do PC. O método SVR se mostrou mais eficiente na predição da característica PC por meio das medidas morfométricas de comprimento e área dorsal, altura e largura peitoral.

## REFERÊNCIAS

AHRENDT, P.; GREGERSEN, T.; KARSTOFT, H. Development of a real-time computer vision system for tracking loose-housed pigs. **Computers and Electronics in Agriculture**, v. 76, n. 2, p. 169-174, mai. 2011. DOI: 10.1016/j.compag.2011.01.011. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169911000263>. Acesso em: 10 Nov. 2021.

ALONSO, J.; CASTÁNÓN, A.R.; BAHAMONDE, A. Support Vector Regression to predict carcass weight in beef cattle in advance of the slaughter. **Computers and Electronics in Agriculture**, v. 91, p. 116-120, fev. 2013. DOI: 10.1016/j.compag.2012.08.009. Disponível em: [https://www.aic.uniovi.es/mlgroup/wp-content/uploads/sites/5/2020/02/carcass\\_weight\\_compag\\_2013.pdf](https://www.aic.uniovi.es/mlgroup/wp-content/uploads/sites/5/2020/02/carcass_weight_compag_2013.pdf). Acesso em: 17 Jan. 2022.

AMERICAN SOCIETY OF AGRICULTURAL AND BIOLOGICAL ENGINEERS. Dimensions of livestock and poultry. St. Joseph, Michigan: **ASABE**. 1985. Disponível em: <https://elibrary.asabe.org/login.asp?search=0&JID=2&AID=37143&CID=s2000&v=&i=&T=2>. Acesso em: 17 Dez. 2021.

ASSOCIAÇÃO BRASILEIRA DE PROTEÍNA ANIMAL. Relatório anual 2020: Carne suína. Brasília, DF: **ABPA**. 2020. Disponível em: [http://abpa-br.org/wp-content/uploads/2020/05/abpa\\_relatorio\\_anual\\_2020\\_portugues\\_web.pdf](http://abpa-br.org/wp-content/uploads/2020/05/abpa_relatorio_anual_2020_portugues_web.pdf). Acesso em: 27 Dez. 2021.

ASSOCIAÇÃO BRASILEIRA DE PROTEÍNA ANIMAL. Estatística do Setor: Suínos. Brasília, DF: **ABPA**. 2021. Disponível em: <http://abpa-br.org/mercados/>. Acesso em: 24 Nov. 2021.

ASSOCIAÇÃO BRASILEIRA DOS CRIADORES DE SUÍNOS. Mapeamento da suinocultura brasileira. Brasília, DF: **ABCS**, 2016. 376p. Disponível em: <https://www.embrapa.br/documents/1355242/0/Mapeamento+da+Suinocultura+Brasileira.pdf>. Acesso em: 24 Nov. 2021.

BANIK, S. et al. Effect of different body measurements on body weight in Ghungroo pigs. **Indian Journal of Animal Sciences**, v. 82, n. 9, p. 1094-1097, set. 2012. Disponível em: <http://krishi.icar.gov.in/jspui/handle/123456789/15176>. Acesso em: 29 Dez. 2021.

CANG, Y.; HE, H.; QIAO, Y. An intelligent pig weights estimate method based on deep learning in sow stall environments. **IEEE Access**, v. 7, p. 164867-164875, nov. 2019. DOI: 10.1109/ACCESS.2019.2953099. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8896840>. Acesso em: 12 Ago. 2021.

CONDOTTA, I.C.F.S. et al. Evaluation of a depth sensor for mass estimation of growing and finishing pigs. **Biosystems Engineering**, v. 173, p. 11-18, set. 2018. DOI: 10.1016/j.biosystemseng.2018.03.002. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1537511017304816>. Acesso em: 15 Dez. 2021.

CONDOTTA, I.C.F.S. et al. Evaluation of low-cost depth cameras for agricultural applications. **Computers and Electronics in Agriculture**, v. 173, jun. 2020. DOI: 10.1016/j.compag.2020.105394. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169919325037>. Acesso em: 24 Jan. 2022.

DANZETTA, M.L. et al. African Swine Fever: Lessons to learn from past eradication experiences. **Frontiers in Veterinary Science**, v. 7, n. 296, p. 1-18, jun. 2020. DOI: 10.3389/fvets.2020.00296. Disponível em: <https://www.frontiersin.org/articles/10.3389/fvets.2020.00296/full>. Acesso em: 06 Mar. 2022.

DAOUD, J.I. Multicollinearity and Regression Analysis. **Journal of Physics: Conference Series**, v. 949, n. 012009, 2017. DOI: doi :10.1088/1742-6596/949/1/012009. Disponível em: <https://iopscience.iop.org/article/10.1088/1742-6596/949/1/012009/pdf>. Acesso em: 30 Dez. 2021.

DENG, N.; TIAN, Y. ZHANG, C. **Support Vector Machines: Theory, Algorithms and Extensions** Philadelphia. 1 ed. Boca Raton: CRC Press, 2012. 345p.

DOUGLAS, S.L. et al. Animal and management factors influencing grower and finisher pig performance and efficiency in European systems: A meta-analysis. **Animal**, v. 9, n. 7, p. 1210-1220, jul. 2015. DOI: 10.1017/s1751731115000269. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1751731115000269>. Acesso em: 20 Out. 2021.

DRAPER, N.; SMITH, H. **Applied Regression Analysis**. 2. ed. New York: John Wiley & Sons, 1981.

EFROYMSON, M.A. **Multiple regression analysis**. In: RALSTON A.; WILF, H.S. *Mathematical Methods for Digital Computers*. (eds.). New York: John Wiley & Sons, 1960.

FERNANDES, A.F.A. et al. A novel automated system to acquire biometric and morphological measurements and predict body weight of pigs via 3D computer vision. **Journal of Animal Science**, v. 97, n. 1, p. 496-508, jan. 2019. DOI: 10.1093/jas/sky418. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC30371785/>. Acesso em: 10 Jan. 2022.

FERNANDES, A.F.A.; DÓREA, J.R.R.; ROSA, G.J.M. Image analysis and computer vision applications in animal sciences: an overview. **Frontiers in Veterinary Science**, v. 7, e551269, out. 2020. DOI: 10.3389/fvets.2020.551269. Disponível em: <https://www.frontiersin.org/articles/10.3389/fvets.2020.551269/full>. Acesso em: 24 Jan. 2022.

FOOD AND AGRICULTURAL ORGANIZATION. Faostat: statistics data base. Roma, Itália: **FAO**. 2020. Disponível em: <https://www.fao.org/faostat/en/#data/QCL>. Acesso em: 27 Dez. 2021.

FOX, J.; WEISBERG, S. **An R companion to applied regression**. 3. ed. Thousand Oaks: SAGE Publications, 2019. Disponível em: <https://socialsciences.mcmaster.ca/jfox/Books/Companion/>. Acesso em: 12 Jan. 2022.

FREITAS, T.S.P.; LYRA, T.M.P. Molecular studies on African swine fever virus from Brazilian isolates. *Arquivos do Instituto Biológico*, v. 85, e0712016, p. 1-8, 2018. DOI: 10.1590/1808-1657000712016. Disponível em: <https://www.scielo.br/j/aib/a/cjWhL7sXQMGWPtQPKqV7PTx/?format=pdf&lang=en>. Acesso em: 06 Mar. 2022.

GÓMEZ, Y. et al. A systematic review on validated precision livestock farming technologies for pig production and its potential to assess animal welfare. *Frontiers in Veterinary Science*, v. 14, n. 8, mai. 2021. DOI: 10.3389/fvets.2021.660565. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC34055949/>. Acesso em: 08 Nov. 2021.

GUIMARÃES, D. et al. **Suinocultura**: estrutura da cadeia produtiva, panorama do setor no Brasil e no mundo e o apoio do BNDES. Brasília, DF: BNDES Setorial 45, 2017, p. 85-136. Disponível em: [https://web.bndes.gov.br/bib/jspui/bitstream/1408/11794/1/BS%2045%20Suinocultura%20-%20estrutura%20da%20cadeia%20produtiva%20-%20panorama%20do%20setor%20no%20Brasil%5B...%5D\\_P.pdf](https://web.bndes.gov.br/bib/jspui/bitstream/1408/11794/1/BS%2045%20Suinocultura%20-%20estrutura%20da%20cadeia%20produtiva%20-%20panorama%20do%20setor%20no%20Brasil%5B...%5D_P.pdf). Acesso em: 21 Dez. 2021.

GUIRADO, A.G. **Crítérios robustos de seleção de modelos de regressão e identificação de pontos aberrantes**. Dissertação (Mestrado em Ciências) - Universidade de São Paulo, Instituto de Matemática e Estatística, São Paulo, SP, 2019. 78p. Disponível em: [https://www.teses.usp.br/teses/disponiveis/45/45133/tde-05042019-165356/publico/dissertacao\\_final.pdf](https://www.teses.usp.br/teses/disponiveis/45/45133/tde-05042019-165356/publico/dissertacao_final.pdf). Acesso em: 30 Dez. 2021.

GUYON, I. et al. Gene Selection for Cancer Classification using Support Vector Machines. *Machine Learning*, v. 46, p. 389-422, jan. 2002. Disponível em: <https://link.springer.com/content/pdf/10.1023/A:1012487302797.pdf>. Acesso em: 12 Jan. 2022.

HAIR JR, J.F. et al. **Análise multivariada de dados**. 5. ed. Porto Alegre: Bookman, 2005.

HARRELL JR, F.E.; DUPONT, C. **Hmisc**: Harrell Miscellaneous. R package version 4.5.0. 2021. Disponível em: <https://CRAN.R-project.org/package=Hmisc>. Acesso em: 12 Jan. 2022.

HARTUNG, J. et al. European farmers' experiences with precision livestock farming systems. *Animal Frontiers*, v. 7, n. 1, p. 38-44, jan. 2017. DOI: 10.2527/af.2017.0107. Disponível em: <https://academic.oup.com/af/article-pdf/7/1/38/32411633/38.pdf>. Acesso em: 06 Nov. 2021.

HOCKING, R.R. The Analysis and Selection of Variables in Linear Regression. *Biometrics*, v. 32, n. 1, p. 1-49, mar. 1976. DOI: 10.2307/2529336. Disponível em: <https://www.jstor.org/institutionSearch?redirectUri=%2fstable%2f2529336&refreqid=excelsior%3A13df7cde71b6b395f94fe45c47b0b382>. Acesso em: 30 Dez. 2021.

HYNDMAN, R.J.; KOEHLER, A.B. Another look at measures of forecast accuracy. *International Journal of Forecasting*, v. 22, n 4, p. 679-688, out/dez. 2006. DOI:10.1016/j.ijforecast.2006.03.001. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0169207006000239>. Acesso em: 30 Dez. 2021.

IGE, A.O. et al. Linear body measurement relationship in white fulani cattle in derived savannah zone of Nigeria. **Journal of Biology, Agriculture and Healthcare**, v. 5, n. 15, 2015. Disponível em: <https://www.iiste.org/Journals/index.php/JBAH/article/view/25098/25702>. Acesso em: 14 Out. 2021.

JUN, K. et al. Estimating pig weights from images without constraint on posture and illumination. **Computers and Electronics in Agriculture**, v. 153, p. 169-176, out. 2018. DOI: 10.1016/j.compag.2018.08.006. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169918304034>. Acesso em: 23 Out. 2021.

KAEWTAPEE, C.; RAKANGTONG, C.; BUNCHASAK, C. Pig weight estimation using image processing and artificial neural networks. **Journal of Advanced Agricultural Technologies**, v. 6, n. 4, p. 253-256, dez. 2019. DOI: Doi: 10.18178/joaat.6.4.253-256. Disponível em: <http://www.joaat.com/uploadfile/2019/1220/20191220115443100.pdf>. Acesso em: 02 Ago. 2021.

KASHIHA, M.A. et al. Automatic monitoring of pig locomotion using image analysis. **Livestock Science**, v. 159, p. 141-148, jan. 2014. DOI: 10.1016/j.livsci.2013.11.007. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1871141313005003>. Acesso em: 12 Jan. 2022.

KONGSRO, J. Estimation of pig weight using a Microsoft Kinect prototype imaging system. **Computers and Electronics in Agriculture**, v. 109, p. 32-35, nov. 2014. DOI: 10.1016/j.compag.2014.08.008. Disponível em: <https://dl.acm.org/doi/abs/10.1016/j.compag.2014.08.008>. Acesso em: 04 Ago. 2021.

KONISHI, S.; KITAGAWA, G. **Information Criteria and Statistical Modeling**. 1. ed. Switzerland: Springer, 2008. 288p.

KUHN, M. et al. **Caret**: Classification and Regression Training. R package version 6.0-88. 2021. Disponível em: <https://CRAN.R-project.org/package=caret>. Acesso em: 12 Jan. 2022.

KUMARI, A. et al. Evaluation of Morphometric Measurements to Estimate Body Weight in Crossbred Landly Pigs (Landrace\*Desi). **Journal of Animal Research**, v. 10, n. 6, p. 1099-1102, dez, 2020. DOI: 10.30954/2277-940X.06.2020.33. Disponível em: <http://ndpublisher.in/admin/issues/JARv10n6z7.pdf>. Acesso em: 29 Dez. 2021.

LEISCH, F.; DIMITRIADOU, E. **Mlbench**: Machine Learning Benchmark Problems. R package version 2.1-3. 2021. Disponível em: <https://cran.r-project.org/web/packages/mlbench/index.html>. Acesso em: 12 Jan. 2022.

MA, S. et al. Scattering transform and LSPTSVM based fault diagnosis of rotating machinery. **Mechanical Systems and Signal Processing**, v. 104, p. 155-170, mai. 2018. DOI: 10.1016/j.ymsp.2017.10.026. Disponível em: <https://ui.adsabs.harvard.edu/abs/2018MSSP..104..155M/abstract>. Acesso em: 17 Jan. 2022.

MARENGONI, M.; STRINGHINI, D. Tutorial: Introdução à Visão Computacional usando OpenCV. **Revista de Informática Teórica e Aplicada**, v. 16, n. 1, p. 125-160, 2009. DOI:



10.22456/2175-2745.11477. Disponível em:  
[https://www.seer.ufrgs.br/rita/article/view/rita\\_v16\\_n1\\_p125/7289](https://www.seer.ufrgs.br/rita/article/view/rita_v16_n1_p125/7289). Acesso em: 02 Jan. 2022.

MATTHEWS, S.G. et al. Early detection of health and welfare compromises through automated detection of behavioural changes in pigs. **The Veterinary Journal**, v. 217, p. 43-51, jan. 2016. DOI: 10.1016/j.tvjl.2016.09.005. Disponível em:  
<https://www.sciencedirect.com/science/article/pii/S1090023316301538/pdf?md5=d565fd5071599a6b035687cab2995a0a&pid=1-s2.0-S1090023316301538-main.pdf>. Acesso em: 19 Out. 2021.

MEYER, D. et al. **E1071**: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien. R package version 1.7-9. 2021. Disponível em:  
<https://CRAN.R-project.org/package=e1071>. Acesso em: 12 Jan. 2021.

MONTGOMERY, D.C.; VINNING, G.C.; PECK, E.A. **Introduction to linear regression analysis**. 3. ed. New York: J Wiley, 2001. 641p.

MONTGOMERY, D.C.; PECK, E.A.; VINING, G.G. **Introduction to linear regression analysis**. 5. ed. New York: J Wiley, 2012. 672p.

MOROTA, G.; VENTURA, VV; SILVA, F.F. et al. Machine learning and data mining advance predictive big data analysis in precision animal agriculture. **Journal of Animal Science**, Londres, v. 96, n. 4, p. 1540–1550, jan. 2018. DOI:10.1093/jas/sky014. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6140937/pdf/sky014.pdf>. Acesso em: 03 Ago. 2021.

MRODE, R.A. **Linear models for the prediction of animal breeding values**. 3. ed. UK: Editora Cabi, 2014. 360p.

MUKAKA, M. M. Statistics Corner: A guide to appropriate use of Correlation coefficient in medical research. **Malawai Medical Journal**, v. 24, n. 3, p. 69-71, set. 2012. Disponível em:  
<https://www.ncbi.nlm.nih.gov/pmc/articles/pmid/23638278/>. Acesso em: 07 Mar. 2022.

NASIRAHMADI, A.; EDWARDS, S.A.; STURM, B. Implementation of machine vision for detecting behaviour of cattle and pigs. **Livestock Science**, v. 202, p. 25-38, ago. 2017. DOI: 10.1016/j.livsci.2017.05.014. Disponível em:  
<https://www.sciencedirect.com/science/article/abs/pii/S1871141317301543>. Acesso em: 16 Dez. 2021.

PEZZUOLO, A. et al. On-barn pig weight estimation based on body measurements by a Kinect v1 depth camera. **Computers and Electronics in Agriculture**, v. 148, p. 29-36, mar. 2018. DOI : 10.1016/j.compag.2018.03.003. Disponível em:  
<https://www.cabdirect.org/cabdirect/abstract/20183162945>. Acesso em: 16 Dez. 2021.

R Development Core Team. **R**: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. 2020. Disponível em: <https://www.R-project.org/>. Acesso em: 03 Jan. 2022.

SCHILLINGS, J.; BENNETT, R.; ROSE, D.C. Exploring the potential of precision livestock farming technologies to help address farm animal welfare. **Frontiers in Animal Science**, v. 2,

e639678, mai. 2021. DOI: 10.3389/fanim.2021.639678. Disponível em: <https://www.frontiersin.org/articles/10.3389/fanim.2021.639678/pdf>. Acesso em: 06 Nov. 2021.

SILVA, G.S. et al. Assessment of biosecurity practices and development of a scoring system in swine farms using item response theory. **Preventive Veterinary Medicine**, v. 1, n. 167, p. 128-136, jun. 2019. DOI: 10.1016/j.prevetmed.2019.03.020. Disponível em: [https://linkinghub.elsevier.com/retrieve/pii/S0167-5877\(18\)30600-7](https://linkinghub.elsevier.com/retrieve/pii/S0167-5877(18)30600-7). Acesso em: 27 Dez. 2021.

SUNGIRAI, M.; MASAKA, L.; BENHURA, T.M. Validity of weight estimation models in pigs reared under different management conditions. **Veterinary Medicine International**, v. 14, n. 530469, p. 1-5, 2014. DOI/10.1155/2014/530469. Disponível em: <https://downloads.hindawi.com/journals/vmi/2014/530469.pdf>. Acesso em: 15 Dez. 2021.

TSANG, IW.; KWOK, J.T.; CHEUNG, P-M. Core vector machines: Fast SVM training on very large data sets. *Journal of Machine Learning Research*, v. 6, n. 13, p. 363-392, 2005. Disponível em: <https://www.jmlr.org/papers/v6/tsang05a.html>. Acesso em: 17 Jan. 2022.

TSCHARKE, M.; BANHAZI, T.M. Review of methods to determine weight and size of livestock from images. **Australian Journal of Multi-Disciplinary Engineering**, Londres, v. 10, n. 1, p.1-17, 2013. DOI: 10.7158/14488388.2013.11464860. Disponível em: <https://www.tandfonline.com/doi/abs/10.7158/14488388.2013.11464860>. Acesso em: 03 Ago. 2021.

VAPNIK, V.N. **Support vector estimation of functions**. In: VAPNIK, V.N. *Statistical Learning Theory*. 1. ed. Hoboken, New Jersey: Wiley-Interscience, 1998. 768p.

VAZ, R.Z. et al. Genetic group and heterosis on morphometric measurements during the growth of male beef cattle. **Semina: Ciências Agrárias**, Londrina, v. 37, n. 4, suplemento 1, p. 2759-2772, jun. 2016. DOI: 10.5433/1679-0359.2016v37n4Supl1p2759. Disponível em: <https://www.uel.br/revistas/uel/index.php/semagrarias/article/download/24727/19658>. Acesso em: 14 Out. 2021.

WANG, K. et al. A portable and automatic Xtion-based measurement system for pig body size. **Computers and Electronics in Agriculture**, v. 148, p. 291-298, mai. 2018. DOI: 10.1016/j.compag.2018.03.018. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169917311845>. Acesso em: 21 Out. 2021.

WHITNALL, T.; PITTS, N. **Global trends in meat consumption**. Australian Government: ABARES Agricultural Commodities, 2019. p. 96-100. Disponível em: [https://www.awe.gov.au/sites/default/files/sitecollectiondocuments/abares/agriculture-commodities/AgCommodities201903\\_MeatConsumptionOutlook\\_v1.0.0.pdf](https://www.awe.gov.au/sites/default/files/sitecollectiondocuments/abares/agriculture-commodities/AgCommodities201903_MeatConsumptionOutlook_v1.0.0.pdf). Acesso em: 24 Jan. 2022.

WICKHAM, H. et al. **Welcome to the tidyverse**. *Journal of Open Source Software*, v. 4, n. 43, nov. 2019. DOI: 10.21105/joss.01686. Disponível em: <https://joss.theoj.org/papers/10.21105/joss.01686>. Acesso em: 24 Jan. 2022.

WILLMOTT, C.; MATSUURA, K.: Advantages of the Mean Absolute Error (MAE) over the Root Mean Square Error (RMSE) in assessing average model performance. **Climate Research**, v. 30, n. 1, p. 79–82, dez. 2005. Disponível em: <https://www.jstor.org/stable/24869236>. Acesso em: 17 Jan. 2022.

WILLMOTT, C.J.; MATSUURA, K.; ROBESON, S.M. Ambiguities inherent in sums-of-squares-based error statistics. **Atmospheric Environment**, v. 43, n. 3, p. 749-752, jan. 2009. DOI: 10.1016/j.atmosenv.2008.10.005. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1352231008009564>. Acesso em: 17 Jan. 2022.

WONGSRIWORAPHON, A. et al. Image analysis for pig recognition based on size and weight. In: International Conference on Industrial Engineering and Engineering Management, 1, 2012. **Anais...** Hong Kong, China: IEEM, 2012. 5p. Disponível em: [https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=6837861&casa\\_token=0EjKVYwLB9kAAAAA:Y7ebt5YIWJ9wI7N7prGjn30N9OrpSBsgiW-L1Q4yOexARzi4Ll\\_fc6hlBn1VMd6vTZqhCb-wXBsWGw&tag=1](https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=6837861&casa_token=0EjKVYwLB9kAAAAA:Y7ebt5YIWJ9wI7N7prGjn30N9OrpSBsgiW-L1Q4yOexARzi4Ll_fc6hlBn1VMd6vTZqhCb-wXBsWGw&tag=1). Acesso em: 20 Jan. 2022.

WOONWONG, Y.; TIEN, D.D.; THANAWONGNUWECH, R. The future of the pig industry after the introduction of African Swine Fever into Asia. **Animal Frontiers**, v. 10, n. 4, p. 30-37, out. 2020. DOI: 10.1093/af/vfaa037. Disponível em: <https://academic.oup.com/af/article/10/4/30/5943513>. Acesso em: 27 Dez. 2021.

WU, G.; BAZER, F.W. Application of new biotechnologies for improvements in swine nutrition and pork production. **Journal of Animal Science and Biotechnology**, v. 10, n. 28, abr. 2019. DOI: 10.1186/s40104-019-0337-6. Disponível em: <https://jasbsci.biomedcentral.com/track/pdf/10.1186/s40104-019-0337-6.pdf>. Acesso em: 27 Dez. 2021.

YOSHIDA, K.; KAWASUE, K. Robust 3D pig measurement in pig farm. In: EUROPEAN CONFERENCE ON COMPUTER VISION, 6, 2018, Munich, Alemanha. **Anais...** Munich: ECCV, 2018. 771p. Disponível em: <https://link.springer.com/content/pdf/10.1007%2F978-3-030-11009-3.pdf>. Acesso em: 04 Nov. 2021.

YU, H., LEE, K., MOROTA, G. Forecasting dynamic body weight of nonrestrained pigs from images using an RGB-D sensor camera. **Transl Anim Sci**. v. 5, n. 1, p. 1-9, jan. 2021. DOI: 10.1093/tas/txab006. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7906448/pdf/txab006.pdf>. Acesso em: 24 Jan. 2022.

ZARAGOZA, L.E.O. **Evaluation of the accuracy of simple body measurements for live weight prediction in growing-finishing pigs**. 2009. Tese (Doutorado em Animal Science) - University of Illinois at Urbana-Champaign, Urbana, Illinois, 2009. 67p. Disponível em: [https://www.ideals.illinois.edu/bitstream/handle/2142/16207/OchoaZaragoza\\_LuisEnrique.pdf?sequence=3&isAllowed=y](https://www.ideals.illinois.edu/bitstream/handle/2142/16207/OchoaZaragoza_LuisEnrique.pdf?sequence=3&isAllowed=y). Acesso em: 12 Dez. 2021.

ZHU, Q. et al. Automatic animal detection from Kinect sensed images for livestock monitoring and assessment. In: INTERNATIONAL CONFERENCE ON COMPUTER AND INFORMATION TECHNOLOGY, 15, 2015, Liverpool, UK. **Anais...** Liverpool:

IEEE/IUCC, 2015, p. 1154-1157. Disponível em:  
<https://ieeexplore.ieee.org/document/7363216>. Acesso em: 15 Dez. 2021.

## ANEXOS

## ANEXO A – TABELAS DA ANÁLISE ESTATÍSTICA

Tabela 8 - Estatística descritiva das medidas morfométricas a partir das imagens laterais\* em pixels.

	<b>CL</b>	<b>AP</b>	<b>AF</b>	<b>P</b>	<b>AL</b>	<b>PL</b>
<b>Média</b>	8740000	5170000	5830000	3060000	268000000	22200000
<b>DP</b>	1130000	746000	942000	516000	65900000	2780000
<b>Mínimo</b>	5310000	2930000	3620000	2030000	111000000	13800000
<b>Máximo</b>	11200000	7090000	8170000	4340000	417000000	28100000
<b>CV (%)</b>	12,92	14,43	16,14	16,86	24,58	12,55

CL = Comprimento Lateral; AP = Altura Peitoral; AF = Altura Flanco; P = Profundidade; AL = Área Lateral; PL = Perímetro Lateral. \*Capturadas pelo telefone móvel.

Tabela 9 - Estatística descritiva das medidas morfométricas retiradas das imagens dorsais\*\* em pixels.

	<b>CD</b>	<b>LP</b>	<b>LF</b>	<b>LA</b>	<b>AD</b>	<b>PD</b>
<b>Média</b>	1070000	328000	331000	332000	3170000	2610000
<b>DP</b>	139000	59900	64400	57300	948000	349000
<b>Mínimo</b>	800000	209000	231000	247000	1850000	1980000
<b>Máximo</b>	1360000	485000	501000	486000	5610000	3390000
<b>CV (%)</b>	12,96	18,27	19,46	17,28	29,92	13,35

CD = Comprimento Dorsal; LP = Largura Peitoral; LF = Largura Flanco; LA = Largura Abdominal. AD = Área Dorsal; PD = Perímetro Dorsal. \*\*Capturadas pelo Kinect®.

Tabela 10 - Variáveis preditoras e seus índices para o modelo matemático completo a partir das imagens reais a partir da metodologia RLM.

	<b>Estimativa</b>	<b>Erro padrão</b>	<b>P-valor</b>	<b>VIF***</b>
<b>(Intercept)</b>	-121,57	6,54	<0,001	
<b>Sexo</b>	1,66	1,45	0,26	1,38
<b>Comprimento Dorsal</b>	0,19	0,11	0,10	3,83
<b>Circunferência Peitoral</b>	0,90	0,26	0,00	22,85
<b>Circunferência Flanco</b>	0,21	0,22	0,34	17,25
<b>Largura Peitoral</b>	0,48	0,46	0,30	7,01
<b>Largura Flanco</b>	0,48	0,43	0,27	5,46
<b>Altura Peitoral</b>	0,45	0,27	0,10	8,75
<b>Altura Flanco</b>	0,19	0,13	0,16	2,62
<b>Profundidade</b>	0,17	0,38	0,66	6,23
<b>R<sup>2</sup></b>		0,96		
<b>R<sup>2</sup> ajustado</b>		0,96		

\*\*\*VIF < 10. *Stepwise* = menor AIC.

Tabela 11 - Variáveis predictoras e seus índices para o modelo matemático completo a partir das imagens laterais\* a partir da metodologia RLM.

	<b>Estimativa</b>	<b>Erro padrão</b>	<b>P-valor</b>	<b>VIF***</b>
<b>(Intercept)</b>	96,33	51,17	0,06637	
<b>Sexo</b>	6,83	5,462	0,21775	1,52
<b>Comprimento Lateral</b>	<0,00114	<0,00111	0,20540	30,45
<b>Altura Peitoral</b>	<0,00102	<0,00107	0,81045	4,78
<b>Altura Flanco</b>	<0,00110	<0,00106	0,13560	7,40
<b>Profundidade</b>	<0,00116	<0,00112	0,18761	7,46
<b>Área Lateral</b>	<0,00101	<0,00100	0,00877	33,67
<b>Perímetro Lateral</b>	<0,00102	<0,00107	0,83773	85,72
<b>R<sup>2</sup></b>		0,57		
<b>R<sup>2</sup> ajustado</b>		0,50		

\*Capturadas pelo telefone móvel. \*\*\*VIF < 10. *Stepwise* = menor AIC.

Tabela 12 - Variáveis predictoras e seus índices para o modelo matemático completo a partir das imagens dorsais\*\* a partir da metodologia RLM.

	<b>Estimativa</b>	<b>Erro padrão</b>	<b>P-valor</b>	<b>VIF***</b>
<b>(Intercept)</b>	-54,71	36,22	0,14	
<b>Sexo</b>	5,154000	2,35100	0,03	1,12
<b>Comprimento Dorsal</b>	<0,00149	<0,0014	0,24	26,74
<b>Largura Peitoral</b>	<0,00137	<0,0014	0,40	5,50
<b>Largura Flanco</b>	<0,00122	<0,0018	0,79	20,88
<b>Largura Abdominal</b>	<0,00130	<0,0016	0,62	9,35
<b>Área Dorsal</b>	<0,00108	<0,0011	0,49	88,33
<b>Perímetro Dorsal</b>	<0,00106	<0,0012	0,80	56,84
<b>R<sup>2</sup></b>		0,89		
<b>R<sup>2</sup> ajustado</b>		0,87		

\*\*Capturadas pelo Kinect®. \*\*\*VIF < 10. *Stepwise* = menor AIC.

Tabela 13 - Variáveis predictoras e seus índices para o modelo matemático completo a partir das imagens laterais\* + dorsais\*\* a partir da metodologia RLM.

	<b>Estimativa</b>	<b>Erro padrão</b>	<b>P-valor</b>	<b>VIF***</b>
<b>(Intercept)</b>	-38,50	44,72	0,39	
<b>Sexo</b>	2,576000	2,648000	0,336900	1,62
<b>Comprimento Lateral</b>	<0,00105	<0,00106	0,403800	37,16
<b>Altura Peitoral</b>	<0,00107	<0,00103	0,032400	5,35
<b>Altura Flanco</b>	<0,00103	<0,00103	0,417000	9,03
<b>Profundidade</b>	-<0,00103	<0,00106	0,664800	8,90
<b>Área Lateral</b>	<0,00100	<0,00100	0,197600	42,62
<b>Perímetro Lateral</b>	-<0,00106	<0,00104	0,111400	99,21
<b>Comprimento Dorsal</b>	<0,00164	<0,00141	0,126300	29,54
<b>Largura Peitoral</b>	<0,00141	<0,00142	0,344800	5,84
<b>Largura Flanco</b>	-<0,00115	<0,00181	0,858000	24,51
<b>Largura Abdominal</b>	<0,00167	<0,00160	0,270100	10,66
<b>Área Dorsal</b>	<0,00107	<0,00111	0,530500	97,77
<b>Perímetro Dorsal</b>	<0,00100	<0,00123	0,985200	58,91
<b>R2</b>		0,91		
<b>R2 ajustado</b>		0,89		

\*Capturadas pelo telefone móvel. \*\*Capturadas pelo Kinect®. \*\*\*VIF < 10. *Stepwise* = menor AIC.