



**UNIVERSIDADE FEDERAL DO PIAUÍ**  
**CENTRO DE CIÊNCIAS AGRÁRIAS**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA ANIMAL**

**LILIAN ROSALINA GOMES SILVA**

**PREDIÇÃO DE PESO A PARTIR DE MEDIDAS LINEARES E APLICAÇÃO NA  
AVALIAÇÃO GENÉTICA DE OVINOS**

**TERESINA**

**2024**

**LILIAN ROSALINA GOMES SILVA**

**PREDIÇÃO DE PESO A PARTIR DE MEDIDAS LINEARES E APLICAÇÃO NA  
AVALIAÇÃO GENÉTICA DE OVINOS**

Tese apresentada ao Programa de Pós-Graduação em  
Ciência Animal da Universidade Federal do Piauí  
como requisito para obtenção do título de Doutora  
em Ciência Animal.

Área de concentração: Produção Animal

**Orientador:** Prof. Dr. José Lindenberg Rocha  
Sarmiento

TERESINA

2024

FICHA CATALOGRÁFICA  
Universidade Federal do Piauí  
Biblioteca Comunitária Jornalista Carlos Castello Branco  
Divisão de Representação da Informação

S586p Silva, Lilian Rosalina Gomes.  
Predição de peso a partir de medidas lineares e aplicação na  
avaliação genética de ovinos / Lilian Rosalina Gomes Silva. --  
2024.  
89 f.

Tese (Doutorado) – Universidade Federal do Piauí,  
Programa de Pós-Graduação em Ciência Animal, Teresina,  
2024.  
“Orientador: Prof. Dr. José Lindenberg Rocha Sarmiento”.

1. Ovinocultura. 2. Avaliação genética. 3. Peso vivo.  
4. Produção de carne. 5. Regressão Linear. I. Sarmiento, José  
Lindenberg Rocha. II. Título.

CDD 636.3

Bibliotecária: Francisca das Chagas Dias Leite – CRB3/1004

**LILIAN ROSALINA GOMES SILVA**

**PREDIÇÃO DE PESO A PARTIR DE MEDIDAS LINEARES E APLICAÇÃO NA  
AVALIAÇÃO GENÉTICA DE OVINOS**

Tese apresentada ao Programa de Pós-Graduação em  
Ciência Animal da Universidade Federal do Piauí  
como requisito para obtenção do título de Doutora  
em Ciência Animal.

Área de concentração: Produção Animal

**Orientador:** Prof. Dr. José Lindenberg Rocha  
Sarmiento

**BANCA EXAMINADORA**

---

Prof. Dr. José Lindenberg Rocha Sarmiento (UFPI)  
Orientador

---

Prof. Dr. Natanael Pereira da Silva Santos (UFPI)  
Examinador Interno

---

Dra. Bruna Lima Barbosa (SEBRAE)  
Examinadora Externa à Instituição

---

Dr. Luiz Antonio Silva Figueiredo Filho (IFMA)  
Examinador Externo à Instituição

---

Prof. Dr. Flávio Henrique Duarte de Araújo (UFPI)  
Examinador Externo ao Programa

*Dedico este trabalho ao meu esposo, Romuere Silva, por todo carinho, paciência, sabedoria e auxílio necessário que me atribuiu para chegar ao fim desta jornada.*

## **AGRADECIMENTOS**

Agradeço a Deus, que me deu o dom da vida, sabedoria, paciência e coragem para trilhar o caminho por mim escolhido.

Agradeço a oportunidade e confiança depositada em mim por meu estimado orientador Dr. José Lindenberg Rocha Sarmiento.

Agradeço a minha mãe Francisca Gírlene da Conceição e ao meu Irmão José Milton Gomes, pois sempre me incentivaram na vida acadêmica, sempre acreditaram no meu potencial e jamais me deixaram desistir diante das dificuldades surgidas ao longo do caminho.

Agradeço ao meu companheiro Dr. Romuere Rodrigues Veloso e Silva. Seu papel foi crucial do início ao fim dessa jornada. Jamais me deixou desamparada e mostrou com lealdade, amor e paciência que tudo é possível quando persistimos naquilo que almejamos conquistar. Obrigada por me ajudar em todo esse processo do doutorado e me provocar a ser a melhor versão de mim. Esse título é meu e seu.

Agradeço a minha psicopedagoga Jaira Celia Basto Liarte, pela dedicação e carinho. Por fazer muitos mais do que seu papel como profissional. Obrigada por me apoiar, por ajudar com meu processo de desenvolvimento. Você foi um verdadeiro anjo em minha vida.

Ao apoio da Coordenação de Aperfeiçoamento de Pessoal Nível Superior – Brasil (CAPES) pelo apoio financeiro. Ao Instituto Federal do Piauí (IFPI) pelo afastamento para cursar a pós-graduação.

*“A imaginação é mais importante que o conhecimento. O conhecimento é limitado, enquanto a imaginação abraça o mundo inteiro, estimulando o progresso, e dando origem à evolução.”*

*Albert Einstein*

## RESUMO

A ovinocultura é um setor essencial para a economia, contribuindo com produtos valiosos como carne, leite, lã e couro. Em 2022, o rebanho mundial de ovinos atingiu 1,2 bilhão de cabeças, com a Ásia liderando a produção. No Brasil, a ovinocultura destaca-se especialmente no segmento de carne, refletindo o potencial do setor, mas com demandas para crescimento e modernização. Desafios como a falta de tecnologia simples para pequenos produtores, como acesso a balanças, ressaltam a necessidade de métodos alternativos para estimar o peso dos animais, crucial para o manejo eficiente do rebanho. Este estudo aborda a importância do uso de medidas lineares na predição de peso em ovinos, utilizando medidas corporais como uma ferramenta prática para superar limitações de infraestrutura, assim como a viabilidade do uso desses pesos em estudos genéticos. A análise de características morfométricas em ovinos da raça Santa Inês mostra que modelos de regressão podem prever o peso corporal, facilitando o manejo e a seleção genética, o que permite decisões mais acertadas. Modelos como regressão Linear, Ridge, *MultiLayer Perceptron* e *Random Forest* foram avaliados, com a regressão Linear e a Ridge apresentando os melhores resultados, explicando cerca de 80,75% da variação nos dados. A seleção de características mais relevantes, como perímetro torácico, perímetro da canela e comprimento corporal, permitiu maior eficácia na predição do peso, com um número reduzido de medidas. Essa abordagem oferece uma solução prática para produtores, especialmente em contextos de criação pouco tecnificada, onde recursos são limitados. A partir dos resultados para predição de peso, foi realizada avaliação genética, para analisar a eficiência da avaliação genética animal com base nos pesos preditos, quando comparado aos preditos a partir do peso real. Para isso, foram estimados os parâmetros genéticos utilizando o peso observado e o peso predito. Como resultado, obteve-se uma herdabilidade de 0,38 para peso observado e 0,29 para peso predito, além de uma correlação de Spearman de 0,85 entre os valores genéticos preditos para as duas características. Pode-se concluir que o uso do peso predito na seleção genética de ovinos Santa Inês é viável na impossibilidade de uso de pesos obtidos por balança, uma vez que seu uso pode trazer uma confiabilidade menor na seleção genética.

Palavras-chave: Avaliação genética. Ovinocultura. Peso vivo. Produção de carne. Regressão Linear.



## ABSTRACT

Sheep farming is an essential sector for the economy, contributing valuable products such as meat, milk, wool and leather. In 2022, the global sheep herd reached 1.2 billion heads, with Asia leading production. In Brazil, sheep farming stands out especially in the meat segment, reflecting the sector's potential, but with demands for growth and modernization. Challenges such as the lack of simple technology for small producers, such as access to scales, highlight the need for alternative methods to estimate animal weight, crucial for efficient herd management. This study addresses the importance of using linear measurements in weight prediction in sheep, using body measurements as a practical tool to overcome infrastructure limitations, as well as predicting the use of these weights in genetic studies. An analysis of morphometric characteristics in Santa Inês sheep can show that regression models predict body weight, facilitating management and genetic selection, which allows for better decisions. Models such as Linear regression, Ridge, MultiLayer Perceptron and Random Forest were evaluated, with Linear and Ridge regression presenting the best results, explaining around 80.75% of the variation in the data. The selection of the most relevant characteristics, such as chest circumference, shin circumference and body length, allowed greater effectiveness in weight prediction, with a reduced number of measurements. This approach offers a practical solution for producers, especially in low-tech farming contexts where resources are limited. Based on the results for weight prediction, genetic evaluation was carried out to analyze the efficiency of animal genetic evaluation based on predicted weights, when compared to those predicted based on the actual weight. For this, genetic parameters were estimated using the observed weight and the predicted weight. As a result, a heritability of 0.38 per offered weight and 0.29 per predicted weight was obtained, in addition to a Spearman demonstration of 0.85 between the predicted genetic values for the two traits. It can be concluded that the use of predicted weight in the genetic selection of Santa Inês sheep is viable if it is impossible to use weights obtained by scales, since their use can bring less reliability in genetic selection.

**Keywords:** Sheep farming. Sheep weight. Genetic evaluation. Feature selection.

## SUMÁRIO

<b>1 INTRODUÇÃO GERAL</b>	10
<b>2 REFERÊNCIAS</b>	11
<b>CAPÍTULO I - PREDIÇÃO DE PESO E AVALIAÇÃO GENÉTICA EM OVINOS: UMA REVISÃO</b>	13
<b>1 INTRODUÇÃO</b>	15
<b>2 DESENVOLVIMENTO</b>	18
2.1 Cadeia produtiva ovina e importância das pesagens para o sistema de produção de carne	18
2.2 Descrição das medidas lineares e predição de peso	21
2.3 Ferramentas de regressão para predição de peso em ovinos	25
2.4 Avaliação e estimação de parâmetros genéticos	28
2.5 Avaliação genética em ovinos de corte	31
<b>3 CONCLUSÃO</b>	33
<b>4 AGRADECIMENTOS</b>	33
<b>5 DECLARAÇÃO DE CONFLITOS DE INTERESSE</b>	33
<b>6 REFERÊNCIAS</b>	33
<b>CAPÍTULO II - PREDIÇÃO DE PESO VIVO EM OVINOS SANTA INÊS A PARTIR DE MEDIDAS LINEARES</b>	43
<b>1 INTRODUÇÃO</b>	45
<b>2 MATERIAL E MÉTODOS</b>	47
2.1 Aquisição da Base de Dados	48
2.2 Pré-Processamento	49
2.3 Seleção de Características	50
2.4 Predição de Peso	50
2.5 Experimentos e Métricas de Avaliação	51
<b>3 RESULTADOS</b>	52
<b>4 DISCUSSÃO</b>	61
<b>5 CONCLUSÃO</b>	65
<b>6 AGRADECIMENTOS</b>	66
<b>7 REFERÊNCIAS</b>	67
<b>CAPÍTULO III - AVALIAÇÃO GENÉTICA PARA PESO PREDITO EM OVINOS DA RAÇA SANTA INÊS</b>	71
<b>1 INTRODUÇÃO</b>	73

<b>2 MATERIAL E MÉTODOS</b>	74
2.1 População amostrada	74
2.2 Dados fenotípicos	75
2.3 Edição e controle de qualidade dos dados fenotípicos	76
2.4 Avaliação Genética	76
<b>3 RESULTADOS</b>	78
<b>4 DISCUSSÃO</b>	80
<b>5 CONCLUSÃO</b>	85
<b>6 REFERÊNCIAS</b>	85
<b>CONSIDERAÇÕES FINAIS</b>	88

## 1 INTRODUÇÃO GERAL

A criação de pequenos ruminantes, desempenha um papel importante na economia e na subsistência de inúmeras famílias ao redor do globo. A relevância desses animais se estende pela produção de carne, leite, lã e couro, sendo uma atividade milenar que evoluiu para se adaptar a diversos contextos econômicos e ambientais (Roessler, 2019). Os ovinos, em particular, destacam-se pela sua extraordinária capacidade de adaptação, habitando desde regiões áridas até áreas montanhosas, o que contribui para a disseminação global da ovinocultura (Abied et al., 2020).

Em termos quantitativos, a população ovina mundial ultrapassou 1,2 bilhão de cabeças em 2022, um aumento significativo em relação a anos anteriores, com a Ásia liderando como o maior produtor, o que reflete não apenas a capacidade adaptativa desses animais, mas também a importância cultural e econômica que possuem em diversas regiões (FAO, 2022). No Brasil, a prática da ovinocultura também se mostra relevante, com um rebanho de aproximadamente 21,5 milhões de ovinos, concentrando-se majoritariamente no Nordeste do país (IBGE, 2022). Esta atividade não apenas fortalece o setor agropecuário brasileiro, mas também se apresenta como uma fonte de proteína de alto valor nutricional para a população (Aksoy & Ulutas, 2016).

A eficiência reprodutiva e produtiva dos ovinos, associada à sua versatilidade, ressalta a importância desses animais na segurança alimentar e no fornecimento de matérias-primas essenciais. Contudo, para maximizar o potencial produtivo do rebanho, práticas de manejo zootécnico, como o controle de peso e medidas lineares, são fundamentais, ainda que enfrentem desafios de implementação devido a limitações de recursos em algumas regiões (Souza et al., 2009; Castro et al., 2012). A utilização de medidas lineares para prever o peso corporal emerge como uma solução prática, permitindo a seleção de animais com características fenotípicas desejáveis e aprimorando a saúde e a produtividade do rebanho (Souza et al., 2009; Castro et al., 2012; Grandis et al., 2018; Souza et al., 2019).

Além das práticas de manejo, o melhoramento genético ocupa um papel central no desenvolvimento da ovinocultura. A seleção de animais com base em avaliações genéticas permite a identificação de indivíduos com superioridade genética para características desejadas, como o peso ao nascer, crescimento e qualidade da carne, potencializando os

ganhos produtivos e a sustentabilidade da atividade (Sarmiento et al., 2016; Olasege et al., 2019; Alves et al., 2020).

Este estudo se insere nesse contexto, propondo uma metodologia para a predição do peso corporal em ovinos a partir de medidas lineares, visando contribuir para o aprimoramento genético e a seleção de animais. A abordagem adotada visa não apenas otimizar os recursos disponíveis para os criadores, mas também proporcionar uma base científica sólida para o desenvolvimento de estratégias de melhoramento genético, fundamentais para a evolução sustentável da ovinocultura no Brasil e no mundo.

A Tese é apresentada em Capítulos, de acordo com as Normas do Programa de Pós-Graduação em Ciência Animal da UFPI. São apresentados a seguir os capítulos formatados de acordo com as normas de revistas para as quais serão realizadas as submissões dos artigos oriundos da tese, como descritos a seguir: Capítulo I - “Predição de peso e avaliação genética em ovinos: uma revisão”, nas normas da revista *Ciência Rural* (ISSN 1678-4596); Capítulo II - “Predição de peso vivo em ovinos a partir de medidas lineares”, nas normas da revista *Livestock Science* (ISSN 1871-1413); e, Capítulo III "Avaliação genética para peso predito em ovinos a partir de medidas lineares", nas normas da revista *Tropical Animal Health and Production* (ISSN 1573-7438). Ao final, são apresentadas as Considerações Finais, em que são mostrados os principais aspectos inerentes à aplicação e relevância desta pesquisa.

## Referências

- ABIÉD, A., et al. Genomic Diversity, Population Structure, and Signature of Selection in Five Chinese Native Sheep Breeds Adapted to Extreme Environments. **Genes**. v. 11, p. 494, 2020.
- AKSOY, Y.; ULUTAS, Z. Meat production traits of local Karayaka sheep in Turkey 1. The meat quality characteristic of lambs. **Italian Journal of Food Science**, v. 28, p. 131-138. 2016.
- ALVES K. et al.. Estimation of additive and non-additive genetic effects for fertility and reproduction traits in North American Holstein cattle using genomic information. **Journal of Animal Breeding and Genetics**. 2020. v. 137(3). p. 316-330.

- CASTRO, F. A. B. et al. Desempenho de cordeiros Santa Inês do nascimento ao desmame filhos de ovelhas alimentadas com diferentes níveis de energia. **Semina: Ciências Agrárias**, v. 33 (6Supl2), p. 3379-3388. 2012.
- FAO. Relatório Anual de Produção Animal 2022. Organização das Nações Unidas para Alimentação e Agricultura, 2022.
- GRANDIS, F. A. et al. Relação entre medidas biométricas e peso corporal em ovinos da raça Texel. **Veterinária e Zootecnia**. v. 25(2), p. 1-8. 2018.
- IBGE. Censo Agropecuário 2022. Instituto Brasileiro de Geografia e Estatística, 2022.
- OLASEGE B.S. et al. Genetic parameter estimates for body conformation traits using composite index, principal component, and factor analysis. **Journal of Dairy Science**. 2019, v. 102(6). p. 5219-5229. Available at <<https://doi.org/10.3168/jds.2018-15561>> Accessed: 15 mar 2023.
- ROESSLER, R. Selection decisions and trait preferences for local and imported cattle and sheep breeds in Peri-/Urban livestock production systems in Ouagadougou, Burkina Faso. **Animals**. v. 9(5), p. 1-24. 2019.
- SARMENTO, J. L. R., et al. Random regression models for the estimation of genetic and environmental covariance functions for growth traits in Santa Ines sheep. **Genetics and Molecular Research**, v. 15, p. 1-13, 2016.
- SOUZA, S. et al. Utilização de medidas biométricas para estimar peso vivo em ovinos. **Archivos Latinoamericanos de Producción Animal**. v. 17(3), p. 61-66. 2009.
- SOUZA, J. S. et al. Biometric measurements of Santa Inês meat sheep reared on Brachiaria brizantha pastures in Northeast Brazil. **Plos One**. v. 14(7). p. 1-16. 2019.

# **CAPÍTULO I**

**Predição de peso e avaliação genética em ovinos: uma revisão**

## **Body weight prediction and genetic evaluation in sheep: a review**

### **Predição de peso e avaliação genética em ovinos: uma revisão**

Lilian Rosalina Gomes Silva<sup>1,2\*</sup>, José Lindenberg Rocha Sarmiento<sup>1</sup>

#### **ABSTRACT**

The present study addresses the importance of weight prediction in sheep (*Ovis aries*) as a crucial tool for efficient management and genetic improvement of flocks. Sheep farming, significant for the economy, faces challenges in weight monitoring due to a lack of adequate resources. Linear body measurements, such as thoracic perimeter and height at withers, are effective alternatives for predicting weight, allowing for more precise management and improvements in genetic selection. This literature review is organized as follows: The importance of weighing sheep; Sheep production chain; Tools for weight prediction; Methods for genetic evaluation and estimation; and Genetic evaluation in meat sheep. The research utilized linear body measurement data from sheep, employing different regression models to estimate body weight. The results indicate that the inclusion of multiple characteristics improves the accuracy of predictions, highlighting the importance of integrated approaches to optimize productivity and sustainability in sheep farming. The study concludes that the use of advanced weighing technologies and genetic evaluation can revolutionize flock management, promoting significant gains in productivity and animal welfare.

Keywords: Weight Prediction, Linear Measurements, Regression Models, Genetic Evaluation.

#### **RESUMO**

O presente estudo aborda a importância da predição de peso em ovinos (*Ovis aries*) como ferramenta crucial para o manejo eficiente e a melhoria genética dos rebanhos. A criação de ovinos, significativa para a economia, enfrenta desafios no monitoramento de peso devido à

<sup>1</sup> Programa de Pós-graduação em Ciência Animal, Universidade Federal do Piauí (UFPI), Teresina, PI, Brasil.

<sup>2</sup> Instituto Federal de Educação, Ciência e Tecnologia do Piauí (IFPI), Campus Valença, Valença, PI, Brasil.

\*Corresponding author.



falta de recursos adequados. Medidas corporais lineares, como perímetro torácico e altura na cernelha, são alternativas eficazes para prever o peso, permitindo uma gestão mais precisa e melhorias na seleção genética. Esta revisão de literatura está organizada da seguinte forma: A importância da pesagem dos ovinos; Cadeia produtiva ovina; Ferramentas para predição de peso: Métodos de avaliação e estimação genética; e Avaliação genética em ovinos de corte. A pesquisa utilizou dados de medidas lineares de ovinos, empregando diferentes modelos de regressão para estimar o peso corporal. Os resultados indicam que a inclusão de múltiplas características melhora a precisão das predições, evidenciando a importância de abordagens integradas para otimizar a produtividade e a sustentabilidade da ovinocultura. O estudo conclui que a utilização de tecnologias de pesagem e avaliação genética avançadas pode revolucionar a gestão de rebanhos, promovendo ganhos significativos em produtividade e bem-estar animal.

**Palavras-chave:** Predição de Peso, Medidas Lineares, Modelos de Regressão, Avaliação genética.

## **INTRODUÇÃO**

A criação de pequenos ruminantes é uma atividade essencial para a economia e a subsistência de muitas famílias, com os ovinos (*Ovis aries*) responsáveis por grande parte da produção de carne, leite, lã e couro (ROESSLER, 2019). A criação de ovinos é uma prática disseminada globalmente, impulsionada pela notável capacidade de adaptação dessa espécie, encontrada em uma ampla gama de ambientes, desde regiões desérticas até os picos gelados dos alpes (ABIÉD et al., 2020).

Em 2022, o rebanho mundial de ovinos era da ordem de 1,2 bilhão de cabeças, no qual houve um aumento de 5,5% quando comparado com o rebanho de 2016. O continente asiático é o principal produtor de ovinos no mundo, detendo 43,34% do rebanho mundial, sendo a

forte cultura de criação e consumo de carne ovina responsável por este percentual (FAO, 2022).

No Brasil, a ovinocultura atingiu em 2022 um tamanho efetivo de 21,5 milhões de ovinos segundo o Instituto Brasileiro de Geografia e Estatística (IBGE, 2022). A ovinocultura brasileira é uma atividade de destaque, com a região Nordeste ocupando 69,9% do rebanho total. Segundo AKSOY e ULUTAS (2016), a carne proveniente da criação de ovinos é uma fonte de proteínas de alto valor nutricional benéficas para a saúde humana, que tem despertado o interesse de criadores como uma opção viável e lucrativa.

Os ovinos são versáteis, com eficiência de produção e reprodução, sendo uma importante fonte de alimentos e matérias-primas para a indústria (FARRAG, 2019; AL-THUWAINI, 2021). Segundo SOUZA et al. (2009), animais de produção precisam ser submetidos a acompanhamento, como o controle zootécnico, pois esta ferramenta permite avaliar o desempenho do rebanho, identificar problemas e tomar medidas corretivas. Dentre os índices para o controle zootécnico, o peso é um dos mais importantes. O controle do crescimento e desenvolvimento dos animais é importante para a ovinocultura, mas pode ser difícil de realizar, no caso dos pequenos produtores, devido ao alto custo e à falta de mobilidade das balanças. Dessa forma, alguns produtores improvisam balanças de bovinos, fitas de pesagem e etc., cuja precisão é menor, ou deixam de pesar os animais, podendo isso comprometer a viabilidade econômica da atividade (SOUZA et al., 2009; CASTRO et al., 2012).

As medidas lineares são ferramentas eficazes para predizer o peso corporal de ovinos, permitindo que produtores e melhoristas identifiquem animais com fenótipos desejáveis, melhorando a saúde e a produtividade do rebanho. Medidas como o perímetro torácico (PT), altura na cernelha (AC) e largura do quadril mostram alta correlação com o peso corporal e podem ser obtidas facilmente usando fita métrica ou réguas específicas (SOUZA et al., 2009;

CASTRO et al., 2012). Essas correlações são fundamentais para o desenvolvimento de modelos matemáticos que predizem o peso vivo dos ovinos a partir de suas medidas corporais (GRANDIS et al., 2018; SOUZA et al., 2019). Esse método de predição auxilia significativamente na seleção de animais com características desejáveis, otimizando a gestão e a produtividade do rebanho.

Para que essas predições de peso sejam viáveis no melhoramento genético precisa-se que estas sejam submetidas a avaliações genéticas. Segundo SARMENTO et al. (2016), para melhorar o valor genético de uma raça para produção de carne, é necessário selecionar os indivíduos geneticamente superiores. Isso pode ser feito por meio de avaliações genéticas, que estimam o potencial genético dos animais a partir de características relacionadas ao crescimento. A precisão dessas estimativas depende de vários fatores, incluindo o número de informações utilizadas, o modelo estatístico, o método de estimação dos componentes de variância e os próprios parâmetros genéticos (OLASEGE et al., 2019).

Na avaliação genética, deve-se estimar os valores genéticos aditivos, ou seja, a parte dos componentes genéticos cujas transmissões se consegue prever. Portanto, os parâmetros genéticos estão relacionados aos valores genéticos aditivos dos animais, esses valores são usados para ranquear os animais no que diz respeito à característica de interesse ao qual pretende-se transmitir aos descendentes, e por fim realizar a seleção dos animais (ALVES et al., 2020).

Os programas de melhoramento genético animal são estratégias sistemáticas e científicas voltadas para a seleção e reprodução de animais com características desejáveis, visando a melhoria contínua da qualidade genética de uma população. Esses programas são baseados em princípios de genética e estatística, utilizando ferramentas como a seleção de características fenotípicas e genotípicas, avaliação de desempenho, análise de pedigree e tecnologias de reprodução assistida, como inseminação artificial e transferência de embriões.

O objetivo principal é aumentar a produtividade, eficiência e resistência a doenças dos animais, além de melhorar características específicas de interesse econômico, como a produção de leite em bovinos leiteiros, a produção de carne em bovinos de corte, ou a prolificidade em ovinos e suínos. Os animais desejados são aqueles que apresentam um conjunto de atributos vantajosos, como crescimento rápido, boa conversão alimentar, alta qualidade de carne ou leite, robustez e adaptabilidade ao ambiente. A implementação eficaz desses programas resulta em ganhos genéticos significativos ao longo das gerações, promovendo a sustentabilidade e a competitividade da produção animal (Kosgey e Okeyo, 2006; Simm et al., 2021).

## **DESENVOLVIMENTO**

A pesagem dos ovinos emerge como uma prática vital para a gestão eficiente do sistema de produção de carne, impactando diretamente a produtividade e a qualidade dos produtos ovinos. A seguir, discutiremos a cadeia produtiva ovina e a importância das pesagens para otimizar a eficiência produtiva e a sustentabilidade da ovinocultura. Além disso, serão abordadas as principais ferramentas para predição de peso em ovinos, os métodos para avaliação e estimação de parâmetros genéticos, e a avaliação genética em ovinos de corte.

### ***Cadeia produtiva ovina e importância das pesagens para o sistema de produção de carne***

A cadeia produtiva ovina, tanto no Brasil quanto no mundo, é uma estrutura complexa que abrange desde a criação e manejo dos animais até a transformação e comercialização de produtos derivados, como carne, lã, leite e couro. Globalmente, a ovinocultura é uma atividade de grande relevância econômica, especialmente em países como Austrália, Nova Zelândia e China, que são grandes produtores e exportadores de carne e lã ovina (FAO, 2023). No Brasil, a ovinocultura tem mostrado crescimento significativo, com destaque para as regiões Sul e Nordeste, que apresentam condições climáticas favoráveis e tradição na criação

de ovinos. A cadeia produtiva ovina brasileira é sustentada por pequenas e médias propriedades rurais, desempenhando um papel crucial na geração de emprego e renda em comunidades rurais (IBGE, 2022).

A cadeia produtiva ovina abrange diversas fases, desde a criação e manejo dos animais até a comercialização dos produtos derivados. Os ovinos desempenham um papel crucial na produção de carne, leite, lã e couro, proporcionando uma fonte versátil de recursos para diferentes setores da indústria pecuária. No Brasil, a criação de ovinos desempenha um papel fundamental na sustentação econômica e nutricional de muitas famílias (SORIO, 2017). Diante dessa relevância, o Brasil tem testemunhado aumento na demanda por produtos provenientes da ovinocultura, consolidando sua posição como notável produtor e também como expressivo importador. Isso é evidenciado pela significativa quantidade de animais e produtos desse setor que ingressaram no país desde a década de 1990 (EMBRAPA, 2016).

Quando se direciona a criação de rebanhos para a produção de carne, o ciclo de desenvolvimento varia dependendo do propósito específico: obtenção de cordeiros desmamados, abate para a produção de carne, e criar matrizes e reprodutores (MARTINS, 2010). Os principais destinos dos produtos derivados de ovinos são abatedouros, frigoríficos e unidades de beneficiamento (CODEVASF, 2011). Nestes segmentos, são produzidos diversos produtos, como linguiças, cortes de carnes frescas, salgadas e secas entre outros (SIDERSKY, 2018).

É essencial salientar a desigualdade no acesso à tecnologia de pesagem entre produtores de diferentes escalas. Conforme BANDA & TANGANYIKA (2021) observaram, os pequenos produtores enfrentam desafios substanciais, como restrições econômicas e de infraestrutura, destacando a urgência na implementação de métodos mais acessíveis e práticos para a previsão de peso. Essa discrepância destaca a necessidade imediata de estratégias

adaptadas, especialmente para pequenos produtores que frequentemente carecem de recursos para acessar balanças especializadas.

As implicações da falta de pesagens em animais são abrangentes, impactando no conhecimento do sistema produtivo, o que afeta a eficiência produtiva dos rebanhos e acarreta em prejuízos econômicos significativos. De acordo com as constatações de CHANDRA & COLLIS (2021), em países de baixa e média renda, os pequenos produtores enfrentam desafios únicos na adoção de tecnologias digitais avançadas. Além disso, EBEL (2020) ressalta a importância de uma gestão eficaz para a sustentabilidade das pequenas fazendas, enfatizando a necessidade crítica de estratégias de manejo sustentáveis e adaptadas.

A integração de tecnologias de pesagem e monitoramento na produção ovina pode trazer benefícios significativos. O uso de balanças eletrônicas e sistemas automatizados de registro de dados tem mostrado uma gestão mais precisa e eficiente, melhorando a produtividade e a qualidade da carne ovina. Tais tecnologias permitem um acompanhamento contínuo e detalhado do desenvolvimento dos animais, facilitando a tomada de decisões informadas e oportunas sobre nutrição, saúde e reprodução (GONZÁLEZ-GARCÍA et al., 2013; GONZÁLEZ-GARCÍA et al., 2018).

O uso de tecnologias avançadas na pesagem pode contribuir para a rastreabilidade e a certificação da carne ovina, aspectos cada vez mais valorizados pelos mercados consumidores. A rastreabilidade assegura que os consumidores possam conhecer a origem e as condições de produção da carne que consomem, aumentando a confiança e potencializando o valor de mercado do produto. Por isso, a integração de sistemas de pesagem com tecnologias de rastreamento e gestão de dados representa uma evolução importante para a cadeia produtiva ovina, promovendo transparência e eficiência em todas as etapas do processo produtivo (DI STASIO et al., 2017).

A monitorização regular do peso dos ovinos é igualmente essencial para a implementação de estratégias de alimentação precisas. A avaliação contínua do ganho de peso permite ajustes rápidos nas dietas, garantindo que os ovinos recebam a quantidade adequada de nutrientes para um crescimento saudável e eficiente. Esta prática não apenas melhora a conversão alimentar, mas também reduz o desperdício de alimentos, contribuindo para a sustentabilidade econômica e ambiental da produção (BROW, 2015; TAYLER, 1954).

Por fim, a implementação de programas de pesagem regular é crucial para a detecção precoce de doenças e condições subclínicas nos rebanhos. Segundo pesquisa (referenciar), a perda de peso inexplicada é frequentemente um dos primeiros sinais de problemas de saúde em ovinos. A identificação precoce dessas mudanças permite intervenções rápidas e eficazes, minimizando o impacto das doenças e melhorando o bem-estar animal. Assim, a pesagem regular não só otimiza a produção, mas também promove a saúde e a longevidade dos animais (CAJA et al., 2020).

### ***Descrição de medidas lineares e predição de peso***

Na pecuária, a mensuração do corpo e o peso vivo de animais são bastante utilizados para processos de seleção e pesquisas em animais de produção. Como afirmado por REIS et al. (2008), a avaliação do peso vivo dos animais é essencial para monitorar o crescimento e o estado nutricional do animal, administrar medicamentos, determinar o valor do animal para abate e ajustar dietas.

As medidas lineares em ovinos, ou seja, as medidas físicas do corpo, são obtidas com o uso de fitas métricas, trenas, paquímetros, régua de tecido ou hipômetro, onde sua precisão é importante para garantir a confiabilidade dos resultados. Dentre as principais pode-se citar: perímetro da perna (Pperna), altura da cernelha (AC), altura da garupa (AG), comprimento corporal (CC), altura do peito (AP), perímetro da canela (PC), perímetro torácico (PT), comprimento da garupa (CGA), e comprimento da perna (Cperna)

(MONTROYA-SANTIYANES et al., 2022). Na Figura 1 estão apresentadas as principais medidas lineares tomadas em ovinos.

Em condições de criação extensiva e com instalações pouco estruturadas, o peso dos animais pode ser um desafio. Isso levou os pesquisadores a procurar outras opções, especialmente em situações em que não há registros zootécnicos e a coleta de medidas corporais é escassa. O peso vivo de um pequeno ruminante pode ser calculado medindo seu corpo, de acordo com vários estudos (YILMAZ et al., 2012).

Diferentes estudos têm utilizado modelos de regressão aplicados a dados obtidos com fitas métricas para medir o peso vivo dos animais de produção. A Tabela 1 apresenta uma análise abrangente dos principais trabalhos da literatura que investigam a predição de peso em pequenos ruminantes utilizando medidas lineares. Diferentes estudos aplicaram diversas técnicas de regressão, incluindo regressão linear simples, múltipla e polinomial, além de métodos mais avançados como árvores de regressão, florestas aleatórias e máquinas de vetores de suporte.

Os coeficientes de determinação ( $R^2$ ) variam amplamente entre os estudos, indicando a eficácia das diferentes abordagens e características medidas. Por exemplo, Taye et al. (2011) obtiveram um  $R^2$  de 0,89 utilizando regressão linear simples, múltipla e não linear em ovinos Farta. Em contraste, Conrado et al. (2015) alcançaram um  $R^2$  de 0,53 em caprinos Canindé utilizando regressão linear, quadrática e polinomial, destacando uma menor precisão em comparação com outros estudos.

Shirzeyli et al. (2013) apresentaram um coeficiente de determinação de 0,99 para as raças Mehrbani, Zandi e Shaal, utilizando uma combinação de regressão linear simples, múltipla e polinomial, sugerindo que a precisão das predições pode ser significativamente aprimorada pela escolha adequada das características medidas e técnicas de regressão. Huma et al. (2019) demonstraram a eficácia de métodos avançados de aprendizado de máquina,



como Regression Trees, Random Forests e Support Vector Machine, alcançando um  $R^2$  de 0,916 e um erro médio absoluto (MAE) de 1,242 em ovelhas Balochi. Isso ressalta o potencial dessas técnicas para fornecer previsões mais precisas em comparação com métodos tradicionais de regressão.

Gurgel et al. (2021) e Kumar et al. (2021) obtiveram  $R^2$  de 0,82 e 0,88, respectivamente, utilizando regressão linear em ovelhas Santa Inês e Malpura. A Tabela 1 também evidencia a importância da seleção das características medidas. A inclusão de múltiplas características, como altura da cernelha (AC), altura da garupa (AG), comprimento corporal (CC), perímetro torácico (PT), entre outras, se correlaciona com maiores coeficientes de determinação, sugerindo que a consideração de múltiplas dimensões morfométricas é crucial para a precisão das previsões.

Tabela 1. Principais trabalho da literatura com o objetivo de predição de peso em pequenos ruminantes utilizando medidas lineares. altura da cernelha (AC), altura da garupa (AG), comprimento corporal (CC), altura do peito (AP), perímetro torácico (PT), largura do peito (LP), circunferência escrotal (CE), largura da garupa (LGa), profundidade do peito (PP), coeficiente de determinação ( $R^2$ ), erro médio absoluto (MAE).

Autores	Amostra e Raça	Características	Técnica	Resultados
TAYE, M. et al. (2011)	941 ovinos Farta.	CC, AC, PT, largura pélvica e comprimento da orelha.	Regressão linear simples, múltipla, e não linear.	$R^2 = 0,89$
YILMAZ et al. (2012)	215 ovelhas Karya.	CC, AG, AC, PT, altura das costas, PP, e LP.	Regressão múltipla.	$R^2 = 0,87$ (idade 2 anos). $R^2 = 0,79$ (idade 6 anos).
SHIRZEYLI et al. (2013)	794 ovelhas, 204 Mehrbani, 200 Zandi, 200 Shaal, e 190 Macoei.	AC, PT, CC e largura do quadril	Regressão linear simples e múltipla, e regressão polinomial.	$R^2 = 0,99$ (Mehrbani, Zandi, e Shaal) $R^2 = 0,98$ (Macaoei)
CONRADO et al. (2015)	347 caprinos Canindé	PT, CC e AC.	Regressão linear, quadrática e polinomial.	$R^2 = 0,53$

GRANDIS et al. (2018)	200 ovinos Texel	PT, CC, AC e CE.	Regressão linear e não-linear. Critério de Informação de Akaike (AIC).	$R^2 = 0,93$ (machos) $R^2 = 0,90$ (fêmeas)
SABBIONI et al. (2019)	303 ovelhas Cornigliese	AC, PT, CC, AG, LP, PP, e LGa.	Regressão múltipla.	$R^2 = 0,950$
HUMA (2019)	131 ovelhas Balochi	CC, PT, AC, comprimento escrotal, CE, diâmetro escrotal, comprimento testicular.	Regressão linear e múltipla. <i>Regression Trees. Random Forests. Support Vector Machine.</i>	$R^2 = 0,916$ MAE = 1,242
GURGEL al. (2021)	51 ovelhas Santa Inês	Altura anterior, altura posterior, CC, LP, LGa, PT, e perímetro de barril.	Regressão linear.	$R^2 = 0,82$
KUMAR et al. (2021)	823 ovelhas Malpura	PT e CC.	Regressão linear	$R^2 = 0,88$
DIGE et al. (2022)	142.564	CC, AC, e PT.	Regressão linear	$R^2 = 0.869$

A produção em pequenos ruminantes é geralmente indicada pela relação direta entre o peso vivo e índices zootécnicos, como ganho de peso diário, obtido a partir do peso vivo. O uso de instrumentos simples, como uma fita métrica, pode ajudar a contornar a falta de uma balança. Essa abordagem ajuda os produtores e garante o peso aproximado do animal para a venda ao coletar medidas corporais que estão fortemente relacionadas ao peso do animal (DIGE et al., 2022).

Pesquisas dedicadas à predição de peso vivo em pequenos ruminantes a partir de medidas lineares têm se mostrado uma abordagem extremamente relevante e promissora. Ao longo desses estudos, foi possível verificar a eficácia e a praticidade do uso de características morfométricas aliada aos modelos de regressão e juntamente com avanços em algoritmos de aprendizado de máquina, compondo assim indicadores confiáveis para predizer o peso dos animais sem a necessidade de aquisição de balanças. Além disso, observou-se que as medidas lineares utilizadas em trabalhos que utilizam regressão linear ou aprendizado de máquina não

se modificaram. Essas metodologias oferecem uma alternativa viável às técnicas tradicionais, que muitas vezes são trabalhosas e exigem equipamentos especializados.

### ***Ferramentas de regressão para predição de peso em ovinos***

Como relatado anteriormente, a predição de peso é realizada utilizando regressores. A análise de regressão é utilizada para investigar e modelar relacionamentos entre variáveis (MONTGOMERY et al., 2006). É possível modelar e inferir a relação de uma variável dependente com variáveis independentes específicas. No problema abordado neste trabalho tem-se que a variável dependente é o peso corporal, e as variáveis independentes são as medidas lineares dos ovinos.

### ***Regressor Linear***

O regressor Linear é um algoritmo de aprendizado de máquina comumente usado para prever valores numéricos. Ele é uma abordagem de regressão linear que estima a relação linear entre variáveis de entrada (X) e a variável de saída (y). A equação geral do modelo de regressão linear pode ser escrita como:

$$y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \varepsilon, \quad (1)$$

em que o  $\beta_0$  é o intercepto (ou ponto de corte),  $\beta_1$  a  $\beta_p$  são os coeficientes para cada uma das  $p$  variáveis de entrada,  $X_0$  a  $X_p$  são os valores dessas características e  $\varepsilon$  é o termo de erro (ou resíduo) que representa a variação não explicada pelo modelo.

Este regressor tem como objetivo encontrar os valores dos coeficientes  $\beta_1$  a  $\beta_p$  que minimizam a soma dos erros quadrados, ou seja, a diferença entre os valores preditos pelo modelo e os valores reais do conjunto de dados. Isso é geralmente feito usando o método dos mínimos quadrados ordinários (OLS) (MONTGOMERY et al., 2006). O modelo de regressão Linear é especialmente útil quando há uma relação linear clara entre as características de

entrada e a variável de saída. No entanto, se essa relação não for linear, a performance do modelo pode ser prejudicada e outras abordagens mais complexas devem ser consideradas.

Apesar de ser classificado como um algoritmo simples, o regressor Linear é poderoso, e pode ser usado para prever valores numéricos com base em uma relação linear entre as características de entrada e a variável de saída. No entanto, a relação entre as variáveis de entrada e a variável de saída deve ser linear para que o modelo tenha boa performance (MONTGOMERY et al., 2006).

### ***Regressor Ridge***

O regressor Ridge é um algoritmo de regressão linear utilizado para obter valores numéricos. Ele é especialmente útil quando há muitas características no conjunto de dados, e essas características estão altamente correlacionadas (HOERL & KENNARD, 1970). O objetivo do regressor Ridge é minimizar a soma dos erros quadrados, mas também adicionar um termo de regularização, que penaliza a magnitude dos coeficientes do modelo. Isso ajuda a evitar o sobreajuste e a melhorar a generalização do modelo (BISHOP, 2006).

Uma das principais vantagens do regressor Ridge é sua capacidade de lidar com problemas de multicolinearidade, que ocorrem quando as características estão altamente correlacionadas. Além disso, ele é relativamente fácil de interpretar e de implementar (HOERL & KENNARD, 1970). No entanto, assim como qualquer algoritmo de aprendizado de máquina, o regressor Ridge também apresenta desvantagens. Ele pode não ser tão preciso quanto outros modelos mais complexos, especialmente quando há muitos dados disponíveis. Além disso, ele requer ajuste de um hiperparâmetro adicional, o que pode ser uma tarefa desafiadora em alguns casos (BISHOP, 2006).

### ***MultiLayer Perceptron***

O regressor *Multi-layer Perceptron* (MLP) é um algoritmo de aprendizado supervisionado que é usado para realizar regressão. Ele consiste em uma rede neural com uma

ou mais camadas ocultas que podem executar transformações não lineares nos dados de entrada. O objetivo do MLP é aprender a função que mapeia as características de entrada para o valor de saída desejado (HAYKIN, 2009).

O MLP é treinado utilizando um conjunto de dados de treinamento e um método de otimização, como o gradiente descendente, para ajustar os pesos da rede neural. Ele usa a função de erro quadrático médio para medir a diferença entre as previsões do modelo e os valores de saída reais (HAYKIN, 2009). Uma das principais vantagens do MLP é sua capacidade de lidar com problemas de regressão não lineares complexos (GOODFELLOW, 2016). No entanto, o treinamento do MLP pode ser demorado e pode exigir um grande conjunto de dados de treinamento. Além disso, o MLP é sensível à inicialização dos pesos da rede e pode ser propenso a sobreajuste (HAYKIN, 2009).

### ***Random Forest***

O *Random Forest* é um algoritmo de aprendizado de máquina que pode ser utilizado para realizar regressão. Ele é baseado em uma coleção de árvores de decisão que são construídas de forma aleatória e combinadas para produzir uma previsão. Durante o processo de treinamento, cada árvore é construída a partir de um subconjunto aleatório de características e uma amostra aleatória dos dados de entrada. Isso reduz a correlação entre as árvores e ajuda a evitar o sobreajuste. Uma das principais vantagens do *Random Forest* é sua capacidade de lidar com problemas de regressão complexos e de alta dimensionalidade. Ele é capaz de lidar com características não lineares e de interação, além de lidar bem com dados ausentes ou incompletos (BREIMAN, 2001).

O *Random Forest* é relativamente simples de configurar e pode ser utilizado com poucos parâmetros. Ele também fornece informações sobre a importância das características, permitindo que os usuários entendam como o modelo faz previsões. Por outro lado, ele pode

ser mais lento do que outros algoritmos de regressão e pode ser menos interpretável do que outros modelos de regressão mais simples (BREIMAN, 2001).

### *Avaliação e estimação de parâmetros genéticos*

A avaliação genética desempenha um papel fundamental na pecuária. Ela permite a identificação e seleção dos animais com o melhor potencial genético para características de interesse econômico, como o peso, na ovinocultura. Portanto, compreender e aprimorar a avaliação genética para peso em ovinos é essencial para impulsionar a eficiência e a produtividade da indústria ovina (MEDRADO et al., 2021).

A estimação de parâmetros genéticos em ovinos é um processo fundamental para compreender a variação genética subjacente às características de interesse, como peso, prolificidade e resistência a doenças (ABEBE et al., 2020). O modelo animal (Equação 2) é um modelo estatístico utilizado para estimar esses parâmetros, que considera tanto os efeitos genéticos aditivos quanto os efeitos ambientais e de erro.

$$y = Xb + Za + e, \quad (2)$$

onde  $y$  é o vetor de observações fenotípicas.  $X$  e  $Z$  são matrizes de incidência para os efeitos fixos e aleatórios, respectivamente.  $b$  é o vetor de efeitos fixos.  $a$  é o vetor de efeitos genéticos aditivos.  $e$  é o vetor de erros aleatórios.

A partir da resolução do sistema da Equação 1, é possível estimar os componentes de variância e, conseqüentemente, calcular a herdabilidade ( $h^2$ ), que é a proporção da variância fenotípica explicada pela variância genética (HENDERSON, 1984). A Equação 3 mostra o cálculo da herdabilidade.

$$h^2 = \frac{\sigma_a^2}{\sigma_p^2}, \quad (3)$$

em que  $\sigma_a^2$  é a variância genética aditiva e  $\sigma_p^2$  é a variância fenotípica total. Além disso, a correlação genética entre duas características pode ser estimada a partir da covariância

genética ( $cov_g$ ) e das variâncias genéticas das características envolvidas. A Equação 4 apresenta o cálculo da correlação genética ( $rg$ ).

$$rg = \frac{cov_g}{\sqrt{\sigma_{a1}^2 \cdot \sigma_{a2}^2}}. \quad (4)$$

Os parâmetros genéticos, incluindo herdabilidades e correlações genéticas, são fundamentais para entender o potencial de melhoria através da seleção. Estes parâmetros indicam até que ponto as variações observadas nas características dos animais podem ser atribuídas a fatores genéticos. Por exemplo, a análise de diversidade genética e adaptabilidade ambiental em raças de Merino mostrou a importância de compreender a estrutura genética e as estratégias de reprodução para preservar as raças, assim como para melhorar a produção de carne por meio do cruzamento com outras raças (CECCOBELLI et al., 2023).

Entre as metodologias que têm como base o modelo animal para estimação dos parâmetros genéticos, a Máxima Verossimilhança Restrita (REML) e a Inferência Bayesiana destacam-se. O método REML é utilizado devido a sua capacidade de fornecer estimativas dos componentes de variância, mesmo em modelos complexos com múltiplos efeitos aleatórios (MEYER, 2019). Este método tem sido aplicado com sucesso na genética animal, onde é crucial para a seleção e melhoramento genético (MISZTAL, 2020).

Uma pesquisa realizada por Rodrigues et al. (2021) abordou a problemática das doenças parasitárias que afetam ovinos, causando danos produtivos e econômicos significativos na criação desses animais. O estudo teve como objetivo estimar os parâmetros genéticos para a resistência a vermes (WR) e características associadas, utilizando o modelo animal linear-limiar via inferência Bayesiana em análises de única e múltiplas características. A metodologia envolveu a coleta de dados de um rebanho de ovinos da raça Santa Inês, submetidos a condições naturais de contaminação. As características avaliadas incluíram o número de ovos por grama de fezes (FEC), escore Famacha (FS), escore de condição corporal

(BCS) e hematócrito (HCT), todas coletadas no mesmo dia, com os animais sendo pesados individualmente após 12 horas de jejum. Os resultados indicaram uma baixa magnitude de repetibilidade para as características relacionadas aos vermes. As estimativas de herdabilidade variaram de baixa a alta (0,05 a 0,88), com FEC, HCT, BCS, FS e peso corporal mostrando maior herdabilidade no modelo de múltiplas características devido ao aumento da informação sobre as características. Todas as características de resistência a vermes mostraram correlação genética significativa, e as estimativas de herdabilidade variaram de 0,44 no modelo de uma única característica a 0,88 no modelo de múltiplas características. A conclusão do estudo sugere a inclusão do escore Famacha (FS) como critério de seleção genética ovina para resistência a endoparasitas, utilizando a característica definida pela análise de cluster multivariada, por proporcionar maiores ganhos genéticos em comparação com qualquer característica isolada, além de ser de fácil medição e baixo custo, exibindo maior herdabilidade e repetibilidade, e alta correlação genética com a resistência a vermes.

A Inferência Bayesiana oferece uma abordagem flexível para a estimativa de parâmetros genéticos, incorporando informações prévias e a incerteza nas estimativas de maneira explícita. Esse método tem mostrado ser particularmente útil na análise de dados genômicos complexos, onde a estrutura da população e as relações de parentesco precisam ser consideradas. A Inferência Bayesiana permite a incorporação de informações prévias, o que pode ser extremamente útil em situações onde os dados são escassos ou a estrutura do modelo é complexa (RADJABALIZADEH et al., 2022).

Estudos comparativos entre REML e Inferência Bayesiana indicam que ambas as metodologias têm seus méritos, dependendo do contexto específico e da estrutura dos dados. RADJABALIZADEH et al. (2022) demonstraram que a Inferência Bayesiana pode oferecer vantagens na análise de curvas de crescimento em ovinos, sugerindo que a escolha do método deve ser baseada nas características específicas dos dados e nos objetivos do estudo.



### ***Avaliação genética em ovinos de corte***

A avaliação genética em ovinos de corte é uma área de pesquisa vital para melhorar a eficiência produtiva e a sustentabilidade na produção de carne ovina. Esta avaliação permite fornecer os valores genéticos para que a seleção possa ser praticada com eficiência em ovinos com características genéticas superiores, como maior taxa de crescimento, melhor qualidade de carne e maior resistência a doenças, o que é essencial para o avanço genético dentro de um rebanho (OYIENG et al., 2022, MUCHA et al., 2022). Esse processo envolve a análise de informações fenotípicas e genealógicas de animais dentro de uma população, a fim de estimar os valores genéticos de cada indivíduo (MCLAREN et al., 2023).

A utilização de abordagens integradas e modelos estatísticos avançados oferece novas oportunidades para compreender a complexidade dos sistemas biológicos e para otimizar a produção de carne ovina. Uma avaliação genética bem-sucedida requer a utilização de métodos estatísticos avançados, como o BLUP (*Best Linear Unbiased Prediction*), que leva em consideração informações genéticas e ambientais para estimar os valores genéticos dos animais de forma imparcial (REN et al., 2021). Além disso, o uso de tecnologias genômicas, como SNPs (*Single-Nucleotide Polymorphism*), tem revolucionado a avaliação genética, permitindo uma análise mais precisa e detalhada do perfil genético dos animais (MISZTAL et al., 2020). Essas ferramentas fornecem aos criadores de ovinos uma compreensão mais completa do potencial genético de seus rebanhos e ajudam a orientar estratégias de seleção para melhoramento contínuo.

A avaliação genética utilizando o método BLUP (Melhor Predição Linear Não Viesada) em ovinos tem sido uma área de pesquisa ativa, com estudos focando em diferentes aspectos, desde a precisão da avaliação até a incorporação de informações genômicas. Um estudo detalhado analisou o viés e a precisão das avaliações genéticas em ovinos, utilizando tanto o BLUP quanto o SSGBLUP (Single-Step Genomic BLUP) com a inclusão de

metafundadores e grupos de pais desconhecidos. Este estudo enfatizou a importância de abordar corretamente as lacunas no pedigree para garantir avaliações genéticas justas e precisas (MACEDO et al., 2020).

Outra pesquisa na África do Sul comparou a habilidade preditiva, o viés e a dispersão do BLUP e do SSGBLUP para características de produção e reprodução em ovinos Merino. Este estudo destacou o potencial de aumentar a precisão da predição genômica, apesar de uma população de referência relativamente modesta, e validou o benefício da informação genômica para aprimorar a seleção genética em Merinos sul-africanos (NEL et al., 2024).

Esté van Marle-Köster et al. investigaram em sua pesquisa a diversidade genética e o estado de endogamia de populações locais de bovinos e ovinos na África do Sul. O estudo teve como objetivo fornecer insights para a utilização sustentável desses recursos genéticos adaptados às condições climáticas diversas do país. A metodologia utilizou arrays de genotipagem SNP para avaliar a diversidade genética e o status de endogamia em várias raças de gado e ovelhas, tanto indígenas quanto comerciais. Os principais resultados mostraram diversidade genética moderada entre as populações estudadas, com índices de heterozigosidade variando entre 0,296 e 0,403 para bovinos e 0,327 a 0,367 para ovinos. Níveis ligeiramente mais altos de endogamia foram observados nos bovinos comparados aos ovinos. A análise revelou uma significativa mistura genética dentro de certas raças de gado e uma clara distinção entre raças de ovinos de dupla finalidade, raças de carne e raças indígenas. As conclusões do estudo enfatizam a importância das informações genômicas para a gestão eficaz e conservação dos recursos genéticos locais, ressaltando a necessidade de estratégias bem planejadas para preservar a diversidade genética e adaptar-se às mudanças ambientais.

Esses estudos demonstram a evolução contínua na avaliação genética em ovinos, ressaltando o papel crítico das tecnologias genômicas modernas e métodos estatísticos avançados, como o BLUP, na otimização das estratégias de seleção e melhoramento genético.

## **CONCLUSÃO**

O estudo destacou a importância de metodologias inovadoras para o monitoramento do peso e a avaliação genética em ovinos. A integração de tecnologias avançadas, como a utilização de medidas corporais lineares e modelos de regressão, mostrou-se eficaz na predição do peso corporal dos animais. Os resultados evidenciaram que a combinação de múltiplas características melhora significativamente a precisão das predições, facilitando a seleção de animais com melhor desempenho genético.

Além disso, a avaliação genética, utilizando ferramentas como a Inferência Bayesiana e a Máxima Verossimilhança Restrita (REML), permitiu estimar com maior precisão os parâmetros genéticos, como herdabilidade e correlações genéticas. Esses parâmetros são essenciais para identificar e selecionar animais com características desejáveis, promovendo o avanço genético e a sustentabilidade da ovinocultura.

Portanto, a implementação dessas tecnologias e metodologias não só otimiza a gestão dos rebanhos, mas também contribui para a melhoria da produtividade e do bem-estar animal, possibilitando uma produção mais eficiente e sustentável na ovinocultura .

## **AGRADECIMENTOS**

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

## **DECLARAÇÃO DE CONFLITO DE INTERESSE**

Nós não temos conflito de interesse a declarar.

## **REFERÊNCIAS**

ABEBE, A. S., et al., Breeding practices and trait preferences of smallholder farmers for indigenous sheep in the northwest highlands of Ethiopia: Inputs to design a breeding program.

**PLoS ONE**. v. 15, p. 1-18, 2020. Available at

<<https://doi.org/10.1371/journal.pone.0233040>> Accessed: 120 feb 2024

ABIED, A., et al. Genomic Diversity, Population Structure, and Signature of Selection in Five Chinese Native Sheep Breeds Adapted to Extreme Environments. **Genes**. v. 11, p. 494, 2020.

Available at <<https://doi.org/10.3390/genes11050494>> Accessed: 15 mar 2023.

AKSOY, Y.; ULUTAS, Z. Meat production traits of local Karayaka sheep in Turkey 1. The meat quality characteristic of lambs. **Italian Journal of Food Science**, v. 28, p. 131-138.

2016. Available at <<https://doi.org/10.14674/1120-1770/ijfs.v465>> Accessed: 15 mar 2023.

AL-THUWAINI, T. M. The relationship of hematological parameters with adaptation and reproduction in sheep; A review study. **Iraqi Journal of Veterinary Sciences**, v. 35(3), p.

575-580. 2021. Available at <<https://doi.org/10.33899/ijvs.2020.127253.1490>> Accessed: 14 mar 2023.

ALVES K. et al.. Estimation of additive and non-additive genetic effects for fertility and reproduction traits in North American Holstein cattle using genomic information. **Journal of**

**Animal Breeding and Genetics**. 2020. v. 137(3). p. 316-330. Available at

<<https://doi.org/10.1111/jbg.12466>> Accessed: 15 mar 2023.

BANDA, L. J.; TANGANYIKA, J. Livestock provide more than food in smallholder production systems of developing countries. **Animal Frontiers**, v. 11(2), p. 7-14. 2021.

Available at <<https://doi.org/10.1093/af/vfab001>> Accessed: 15 mar 2023.

BISHOP, C. 2006. Pattern Recognition and Machine Learning. Springer.

BREIMAN, L. Random Forests. **Machine Learning**, 45(1), p.5–32. 2001. Available at

<<https://doi.org/10.1023/A:1010933404324>> Accessed: 15 mar 2023.

BROWN, D.; SAVAGE, D.; HINCH, G.; HATCHER, S. Monitoring liveweight in sheep is a valuable management strategy: a review of available technologies. *Animal Production Science*, v. 55, n. 4, p. 427-436, 2015. doi: 10.1071/AN13274.

CAJA, G. et al. Sensing solutions for improving the performance, health and wellbeing of small ruminants. *J Dairy Res.* 2020 Aug;87(S1):34-46. doi: 10.1017/S0022029920000667. Epub 2020 Jul 30. PMID: 33213578.

CASTRO, F. A. B. et al. Desempenho de cordeiros Santa Inês do nascimento ao desmame filhos de ovelhas alimentadas com diferentes níveis de energia. *Semina: Ciências Agrárias*, v. 33 (6Supl2), p. 3379-3388. 2012. Available at

<<https://doi.org/10.5433/1679-0359.2012v33n6Supl2p3379>> Accessed: 15 mar 2023.

CECCOBELLI, S., et al. A comprehensive analysis of the genetic diversity and environmental adaptability in worldwide Merino and Merino-derived sheep breeds. *Genetics Selection Evolution*. v. 55(24), p 1-18. 2023. Available at

<<https://doi.org/10.1186/s12711-023-00797-z>> Accessed: 15 mar 2023.

CONRADO, V., Arandas, J., Ribeiro, M.: Modelos de regressão para predição do peso da raça canindé através de medidas morfométricas. *Archivos de Zootecnia* 64, 277–280 (2015).

<https://doi.org/10.21071/az.v64i247.400>

CHANDRA, R.; COLLIS, S. (2021). Digital agriculture for small-scale producers: challenges and opportunities. *Communications of the ACM*, v. 64(12), p. 75-84. 2021. Available at

<<https://doi.org/10.1145/3454008>> Accessed: 15 mar 2023.

CODEVASF. Companhia de Desenvolvimento dos Vales do São Francisco e do Parnaíba.

Manual de criação de caprinos e ovinos. 2011. Available at

<<https://www.codevasf.gov.br/aceso-a-informacao/institucional/biblioteca-geraldo-rocha/publicacoes/manuais/manual-de-criacao-de-caprinos-e-ovinos.pdf/view>>. Accessed: 23 jul. 2023.

DIGE, M., et al. Estimates of genetic parameters for linear body measurements and prediction of body weight in goat. **Journal of Animal Breeding and Genetics**. v. 139, p. 1-11, 2022.

Available at <<https://doi.org/10.1111/jbg.12677>>. Accessed: 23 jul. 2023.

DI STASIO, L., et al. Lamb meat traceability: The case of Sambucana sheep. *Small Ruminant Research*, v. 149, p. 85-90. 2017. Available at:<

<https://doi.org/10.1016/j.smallrumres.2017.01.013>>. Accessed in: 18 jul. 2024.

EBEL, R. Are small farms sustainable by nature?—Review of an ongoing misunderstanding in agroecology. **Challenges In Sustainability**, v. 8(1), p. 17-29. 2020. Available at

<<https://doi.org/10.12924/cis2020.08010017>> Accessed: 15 mar 2023.

FAO. Food and agriculture organization of the United Nations. Meat Market Review - Overview of market and policy developments in 2021. Available at

<<https://www.fao.org/3/cc0984en/cc0984en.pdf>>. Accessed: 10 set 2023.

FARRAG, B. Productive characteristics and reproductive responses to estrus synchronization and flushing in Abou-Delik ewes grazing in Arid Rangelands in

Halaieb-Shalateen-Abouramad Triangle of Egypt. **World's Veterinary Journal**. v. 9(3), p.

201-210. 2019. Available at <<https://doi.org/10.36380/scil.2019.wvj26>> Accessed: 15 mar 2023.

HOERL, A., KENNARD, R. Ridge regression: Biased estimation for nonorthogonal problems. **Technometrics**. v. 12(1), p. 55-67. 1970. Available at

<<https://doi.org/10.2307/126735>> Accessed: 15 mar 2023.

GONZÁLEZ-GARCÍA, E.; ALHAMADA, M.; NASCIMENTO, H.; PORTES, D.;

BONNAFE, G.; ALLAIN, C. Measuring liveweight changes in lactating dairy ewes with an automated walk-over-weighing system. *Journal of Dairy Science*, 2013. Available at:

em:<<https://doi.org/10.3168/jds.2020-19075>>. Accessed: 15 jul 2024.

GONZÁLEZ-GARCÍA, E.; ALHAMADA, M.; BONNAFE, G.; ALLAIN, C. An automated walk-over-weighing system for monitoring liveweight change of sheep at pasture. *Livestock Science*, 2018.

GOODFELLOW, I., et al. Deep Learning. 2016. MIT Press.

GRANDIS, F. A. et al. Relação entre medidas biométricas e peso corporal em ovinos da raça Texel. **Veterinária e Zootecnia**. v. 25(2), p. 1-8. 2018. Available at <<https://doi.org/10.35172/rvz.2018.v25.57>> Accessed: 15 mar 2023.

GURGEL, A. L. C. et al. Use of biometrics in the prediction of body weight in crossbred lambs. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**. v. 73, p. 261-264. 2021. Available at <<https://doi.org/10.1590/1678-4162-12087>> Accessed: 15 mar 2023.

HAYKIN, S. Neural Networks and Learning Machines. 2009. Pearson Education.

HENDERSON, C. R. Applications of linear models in animal breeding. 1984. Available at <<http://lib.ugent.be/catalog/rug01:000162616>> Accessed: 15 mar 2023.

HUMA, Z. E.; IQBAL, F. Predicting the body weight of Balochi sheep using a machine learning approach. **Turkish Journal of Veterinary and Animal Sciences**. v. 43, p. 500-506. 2019. Available at <<https://doi.org/10.3906/vet-1812-23>> Accessed: 15 mar 2023.

IBRAHIM, A., et al. Regression model analysis for prediction of body weight from body measurements in female Batur sheep of Banjarnegara District, Indonesia. **Biodiversitas Journal of Biological Diversity**. v. 22 p. 2723-2730. 2021. Available at <<https://doi.org/10.13057/biodiv/d220721>> Accessed: 15 mar 2023.

IBGE. Instituto Brasileiro de Geografia e Estatística. Censo agropecuário: Rebanho de Ovinos (Ovelhas e Carneiros). Rio de Janeiro: IBGE, 2022. Available at: <<https://www.ibge.gov.br/explica/producao-agropecuaria/ovino/br>>. Accessed: 12 out. 2023.

KOSGEY, I. S.; OKEYO, A. M. Genetic improvement of small ruminants in low-input smallholder production systems: Technical and infrastructural issues. *Small Ruminant*

*Research*, [s.l.], 2006. Interbull Bulletin, n. 33, 2005. SLU, Uppsala, Sweden. Available at: <http://www.interbull.org>. Accessed: 17 jun. 2024.

MACEDO, F.L., et al. Bias and accuracy of dairy sheep evaluations using BLUP and SSGBLUP with metafounders and unknown parent groups. **Genetics Selection Evolution**. v. 52 (47), p. 1-10. 2020. Available at: <https://doi.org/10.1186/s12711-020-00567-1> Accessed: 18 jan. 2024.

MARTINS, E. C. Custos de produção de ovinos e caprinos. *Página Rural*. 2010. Available at: <https://www.paginarural.com.br/artigo/2144/custos-de-producao-de-ovinos-e-caprinos>. Accessed: 23 jul. 2020.

MCLAREN, A. et al. Genetic associations of ewe body condition score and lamb rearing performance in extensively managed meat sheep. **Livestock Science**. v. 277, p. 105336. 2023. Available at <https://doi.org/10.1016/j.livsci.2023.105336>. Accessed: 29 ago 2023.

MEDRADO, B. D., et al. Meta-analysis of genetic parameters for economic traits in sheep. **Livestock Science**. v. 247, p. 1-10. 2021. Available at <https://doi.org/10.1016/j.livsci.2021.104477> Accessed: 29 ago 2023.

MEYER K. “Bending” and beyond: Better estimates of quantitative genetic parameters?. **Journal of Animal Breeding and Genetics**. v. 136. p 243-251. 2019. Available at <https://doi.org/10.1111/jbg.12386> Accessed: 15 mar 2023.

MISZTAL, I., et al. Current status of genomic evaluation. **Journal of Animal Science**, v. 98(4), p. 1-14. 2020. Available at <https://doi.org/10.1093/jas/skaa101> Accessed: 29 ago 2023.

MISZTAL I. 295 Parameter estimation under genomic selection. **Journal of Animal Science**. v. 98. p. 31-32. 2020. Available at <https://doi.org/10.1093/jas/skaa278.056> Accessed: 15 mar 2023.



MONTGOMERY, D., et al. Introduction to Linear Regression Analysis. 4 ed. 2006. Wiley & Sons.

MONTOYA-SANTIYANES, L. A., et al. A novel model for estimating the body weight of Pelibuey sheep through Gray Wolf Optimizer algorithm. **Journal of Applied Animal Research**. v. 50(1), p. 635-642. 2022. Available at <<https://doi.org/10.1080/09712119.2022.2123812>> Accessed: 15 mar 2023.

MUCHA, S., et al. Animal Board Invited Review: Meta-analysis of genetic parameters for resilience and efficiency traits in goats and sheep. **Animal**. v. 16(3), p. 1-11. 2022. Available at <<https://doi.org/10.1016/j.animal.2022.100456>>. Accessed: 15 mar 2023.

NEL C., et al. Including genomic information in the genetic evaluation of production and reproduction traits in South African Merino sheep. **Journal of Animal Breeding and Genetics**. v. 141(1), p. 65-82. 2024. Available at <<https://doi.org/10.1111/jbg.12826>> Accessed: 15 mar 2023.

OLASEGE B.S. et al. Genetic parameter estimates for body conformation traits using composite index, principal component, and factor analysis. **Journal of Dairy Science**. 2019, v. 102(6). p. 5219-5229. Available at <<https://doi.org/10.3168/jds.2018-15561>> Accessed: 15 mar 2023.

OYIENG, E., et al. Genetic parameters and genetic trends for growth traits of the Red Maasai sheep and its crosses to Dorper sheep under extensive production system in Kenya. **Small Ruminant Research**. v. 206(1), p. 1-7. 2022. Available at <<https://doi.org/10.1016/j.smallrumres.2021.106588>> Accessed: 15 mar 2023.

RADJABALIZADEH, K. et al. Estimation of genetic parameters of Wood's lactation curve parameters using Bayesian and REML methods for milk production trait of Holstein dairy cattle. **Journal of Applied Animal Research**. v. 50. p. 363-368. 2022. Available at <<https://doi.org/10.1080/09712119.2022.2080211>> Accessed: 15 mar 2023.

REIS, G. L., et al.. Predição do peso vivo a partir de medidas corporais em animais mestiços holandês/gir. **Ciência Rural**. v. 38(3), p. 778-783. 2008. Available at <<https://doi.org/10.1590/S0103-84782008000300029>> Accessed: 15 mar 2023.

REN, D., et al. Efficient weighting methods for genomic best linear-unbiased prediction (BLUP) adapted to the genetic architectures of quantitative traits. **Heredity**. v. 126, p. 320-334. 2021. Available at <<https://doi.org/10.1038/s41437-020-00372-y>> Accessed: 15 mar 2023.

RODRIGUES, F. N.; SARMENTO, J. L. R.; LEAL, T. M.; ARAÚJO, A. M.; FIGUEIREDO FILHO, L. A. S. Genetic parameters for worm resistance in Santa Inês sheep using the Bayesian animal model. *Animal Bioscience*, v. 34, n. 2, p. 185-191, 2021. doi: 10.5713/ajas.19.0634.

ROESSLER, R. Selection decisions and trait preferences for local and imported cattle and sheep breeds in Peri-/Urban livestock production systems in Ouagadougou, Burkina Faso. **Animals**. v. 9(5), p. 1-24. 2019. Available at <<https://doi.org/10.3390/ani9050207>> Accessed: 15 mar 2023.

SABBIONI, A. et al. Body weight estimation from body measures in cornigliese sheep breed. **Italian Journal of Animal Science**, 19(1):25–30, 2020.

SARMENTO, J. L. R., et al. Random regression models for the estimation of genetic and environmental covariance functions for growth traits in Santa Ines sheep. **Genetics and Molecular Research**, v. 15, p. 1-13, 2016. Available at <<http://dx.doi.org/10.4238/gmr.15025749>> Accessed: 15 mar 2023.

SIMM, G.; POLLOTT, G.; MRODE, R.; HOUSTON, R.; MARSHALL, K. Genetic improvement of farmed animals. Wallingford, U.K: CABI, 2021.

SHIRZEYLI, F. H. et al. Estimation of body weight from body measurements in four breeds of Iranian sheep. **Songklanakarin Journal of Science and Technology**. v. 35. p. 507-511.

2013. Available at

<<https://www.semanticscholar.org/paper/Estimation-of-body-weight-from-body-measurements-in-Shirzeyli-Lavvaf/f9f26f0b850034712cba825ab933026da4d0d94f>> Accessed: 15 mar 2023.

SIDÉRSKY, P. R. Sobre a cadeia produtiva da caprinovinocultura no sertão do Piauí: um estudo centrado no território da Chapada do Vale do Itaim (região de Paulistana). **Brasília: FIDA. IICA**. 2018. 94 p. ISBN 978-92-9072-828-3. Available at

<<https://repositorio.iica.int/bitstream/handle/11324/8135/BVE19040264p.pdf>> Accessed: 15 mar 2023.

SORIO, A. Diagnóstico da oferta e demanda de ovinos e caprinos para processamento de carne, pele e leite na região central do Tocantins. **Tocantins: Triunfal**, 2017. Available at

<<https://central3.to.gov.br/arquivo/405313/>> Accessed: 15 mar 2023.

SOUZA, J. S. et al. Biometric measurements of Santa Inês meat sheep reared on Brachiaria brizantha pastures in Northeast Brazil. **Plos One**. v. 14(7). p. 1-16. 2019. Available at

<<https://doi.org/10.1371/journal.pone.0219343>> Accessed: 15 mar 2023.

SOUZA, S. et al. Utilização de medidas biométricas para estimar peso vivo em ovinos.

**Archivos Latinoamericanos de Producción Animal**. v. 17(3), p. 61-66. 2009. Available at

<<http://www.bioline.org.br/pdf?la09009>> Accessed: 15 mar 2023.

TAYLER, J. C. Technique of Weighing the Grazing Animal. 1954, p. 3-16. doi:

10.1017/S0369852100001330.

TAYE, M. et al. Estimation of live body weight from linear body measurements for farta sheep. **Online Journal of Animal and Feed Research**. v. 2(1). p 98-103. 2011. Available at

<[http://www.ojafir.ir/main/index.php?option=com\\_content&view=article&id=82&Itemid=78](http://www.ojafir.ir/main/index.php?option=com_content&view=article&id=82&Itemid=78)>

Accessed: 15 mar 2023.

VAN MARLE-KÖSTER, E. et al. Whole-Genome SNP Characterisation Provides Insight for Sustainable Use of Local South African Livestock Populations. *Frontiers in Genetics*, v. 12, p. 714194, 2021. Disponível em: <https://doi.org/10.3389/fgene.2021.714194>. Acesso em: 18 jul. 2024.

YILMAZ, O. et al. Estimation of mature live weight using some body measurements in karyia sheep. **Tropical animal health and production**. v. 45(2). p. 397-403. 2012. Available at <<https://doi.org/10.1007/s11250-012-0229-7>> Accessed: 15 mar 2023.

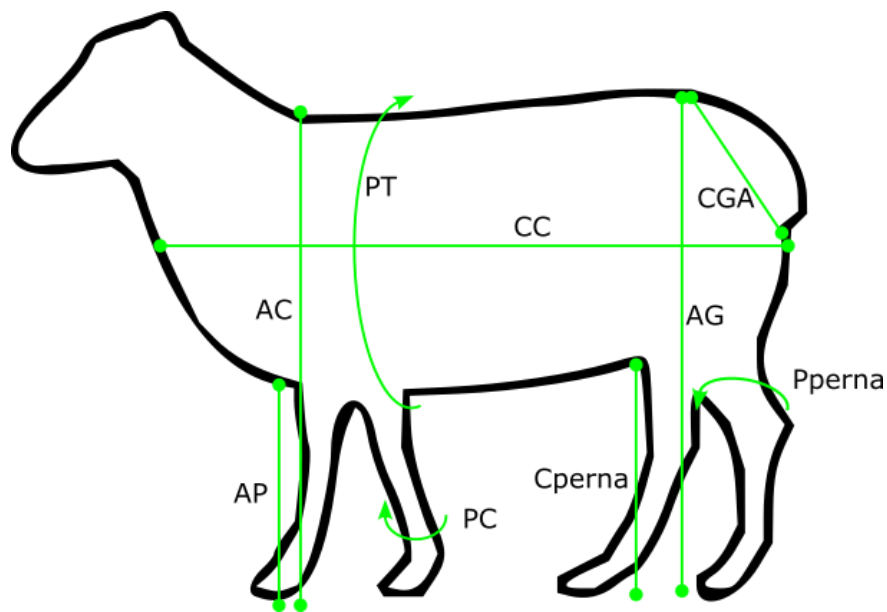


Figura 1. Representação das medidas lineares em ovinos. Perímetro da perna (Pperna), altura da cernelha (AC), altura da garupa (AG), comprimento corporal (CC), altura do peito (AP), perímetro da canela (PC), perímetro torácico (PT), comprimento da garupa (CGA), comprimento da perna (Cperna).

## **CAPÍTULO II**

**Predição de peso vivo em ovinos a partir de medidas lineares**

1 Predição do peso a partir de medidas lineares em ovinos  
2 Santa Inês

3 Lilian Rosalina Gomes Silva<sup>a,b,\*</sup>, José Lindenberg Rocha Sarmiento<sup>a</sup>

<sup>a</sup>*Departamento de Zootecnia Tropical, Universidade Federal do Piauí, Bairro Ininga, Teresina, 64049-550, Piauí, Brazil*

<sup>b</sup>*Campus de Valença, Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Avenida Joaquim Manuel, Valença, 64300-000, Piauí, Brazil*

---

4 **Abstract**

5 O Brasil possui um grande rebanho comercial de ovinos. A ovinocultura  
6 tem potencial de crescimento, mas necessita de modernização, incluindo o  
7 monitoramento preciso das medidas corporais para aprimoramento genético,  
8 nutrição e saúde. Este trabalho visa a análise de características morformétricas  
9 para predição de peso corporal em ovinos, facilitando o manejo e a tomada  
10 de decisões. A metodologia compreendeu cinco etapas: aquisição de dados,  
11 pré-processamento, seleção de características relevantes, treinamento de re-  
12 gressores (Linear, Ridge, *MultiLayer Perceptron*, *Random Forest*) com as  
13 características selecionadas e avaliação dos modelos usando métricas de re-  
14 gressão. Os dados foram coletados de 637 ovinos, incluindo peso corporal (P),  
15 Escore de Condição Corporal (ECC), perímetro da perna (PPerna), altura da  
16 cernelha (AC), altura da garupa (AG), comprimento corporal (CC), altura  
17 do peito (AP), perímetro da canela (PC), perímetro torácico (PT), compri-  
18 mento da garupa (CGa), e comprimento da perna (CPerna). A seleção de  
19 características identificou as mais relevantes usando o teste-F. Foram condu-  
20 zidos dois conjuntos de experimentos: no primeiro, todas as características

---

\*Corresponding author (lilianrosalina@ifpi.edu.br)  
*Preprint submitted to Livestock Science*

21 foram usadas para encontrar o melhor modelo de regressão; no segundo, as  
22 melhores características foram usadas com o melhor regressor do primeiro  
23 conjunto. As métricas de avaliação incluíram Erro Médio Absoluto, Erro  
24 Médio Quadrático e Coeficiente de Determinação. Os resultados mostraram  
25 que a Regressão Linear e a Regressão Ridge explicaram cerca de 80,75% da  
26 variação nos dados, com erros médios de aproximadamente 4,53 kg. As caracte-  
27 rísticas mais relevantes foram PT, PC e CC. A análise incremental mostrou  
28 que usando essas três características produziu-se resultados próximos ao uso  
29 de todas. As estatísticas descritivas indicaram precisão nas médias das esti-  
30 mativas de peso corporal observado e predito. Conclui-se que a estimativa de  
31 peso corporal é eficaz com base em características morfométricas, permitindo  
32 predições precisas e reduzindo a quantidade de características. O estudo ofe-  
33 rece possibilidade de aplicações práticas na estimativa de peso corporal com  
34 equilíbrio entre simplicidade e precisão.

35 *Palavras-Chave:* Regressão Linear, Seleção de atributos, Precisão da  
36 predição

---

## 37 **1. Introdução**

38 A produção de pequenos ruminantes é uma atividade importante para a  
39 segurança alimentar e o desenvolvimento rural em todo o mundo. Segundo  
40 a Organização das Nações Unidas para Alimentação e Agricultura (FAO), a  
41 produção mundial de carne ovina em 2021 atingiu 16,4 milhões de toneladas,  
42 um aumento de 1,8% em relação ao ano anterior, com o maior aumento de  
43 volume originado na Ásia e na América do Sul [1].

44 No Brasil, a ovinocultura é uma atividade tradicional que se perpetua há

45 séculos [2]. É caracterizada por uma diversidade de sistemas de produção,  
46 que variam de rebanhos comerciais de grande escala a pequenos rebanhos  
47 familiares destinados à subsistência. Com mais de 20 milhões de ovinos, o  
48 Brasil está entre os 19 maiores produtores de ovinos do mundo, representando  
49 31,6% do mesmo. O setor ovinocaprino brasileiro enfrenta desafios que exi-  
50 gem soluções inovadoras. Santos et al. (2023) destacaram a necessidade de  
51 melhorias em programas de melhoramento, estratégias nutricionais e práticas  
52 de gestão sanitária para garantir a sustentabilidade e a produtividade a longo  
53 prazo.

54 Nas raças ovinas utilizadas para corte, é de fundamental importância rea-  
55 lizar o monitoramento dos animais com frequência e precisão, principalmente  
56 em relação às medidas corporais [3]. Medidas corporais são utilizadas para  
57 estimar o coeficiente de condicionamento e peso corporal, além de classificar  
58 os melhores fenótipos para animais mais saudáveis, produtivos e com maior  
59 expectativa de vida [4]. Dessa forma, determinar com precisão medidas cor-  
60 porais promove o monitoramento contínuo do rebanho e pode auxiliar na  
61 tomada de decisões tais como: escolher o momento mais conveniente para o  
62 abate; analisar a aderência ao plano alimentar; e, verificar o status sanitário  
63 dos animais pela detecção de doenças parasitárias ou crônicas ligadas à perda  
64 de peso.

65 A aferição do peso de animais em fazendas pode ser problemática, isso  
66 porque as balanças de pesagem normalmente não estão disponíveis em condi-  
67 ções de campo. Tais balanças são relativamente caras, e seus equipamentos  
68 eletrônicos estão propensos a serem danificados devido ao contato das ba-  
69 lanças diretamente com os animais, e à presença de fezes e urina no ambiente



70 em que se realiza as pesagens[5].

71 Uma alternativa ao uso de balanças é fazer a predição do peso corporal  
72 utilizando medidas morfológicas que sejam significativamente relevantes para  
73 o peso, tais como perímetro torácico, altura da cernelha e largura do quadril.  
74 Essas características são usualmente aferidas com uso de fita métrica ou  
75 régua específicas.

76 Medidas corporais, mensuradas diretamente no animal, podem ser utili-  
77 zadas para prever o peso dos animais devido a facilidade de utilização, e a  
78 correlação com o peso [6]. A utilização de modelos de regressão para prever  
79 o peso dos animais, a partir de medidas morfométricas, surgiu como possível  
80 solução para essa problemática [7].

81 Esta pesquisa apresenta duas contribuições principais: i) uma metodolo-  
82 gia completa para predição do peso corporal de ovinos da raça Santa Inês  
83 utilizando medidas corporais; ii) análise e seleção das medidas mais relevan-  
84 tes para a predição, de forma a tornar o método viável em um ambiente  
85 real.

## 86 **2. Material e Métodos**

87 A metodologia para predição de peso proposta consistiu em cinco eta-  
88 pas: i) aquisição dos dados junto a produtores de ovinos da raça Santa Inês;  
89 ii) pré-processamento dos dados; iii) seleção características importantes ao  
90 problema de forma a diminuir a complexidade do sistema de predição; iv)  
91 utilização dos dados processados como entrada em algoritmos de regressão  
92 para treinamento dos modelos de predição; v) predição do peso; e, vi) ava-  
93 liação dos experimentos utilizando métricas de acurácia para regressão. A

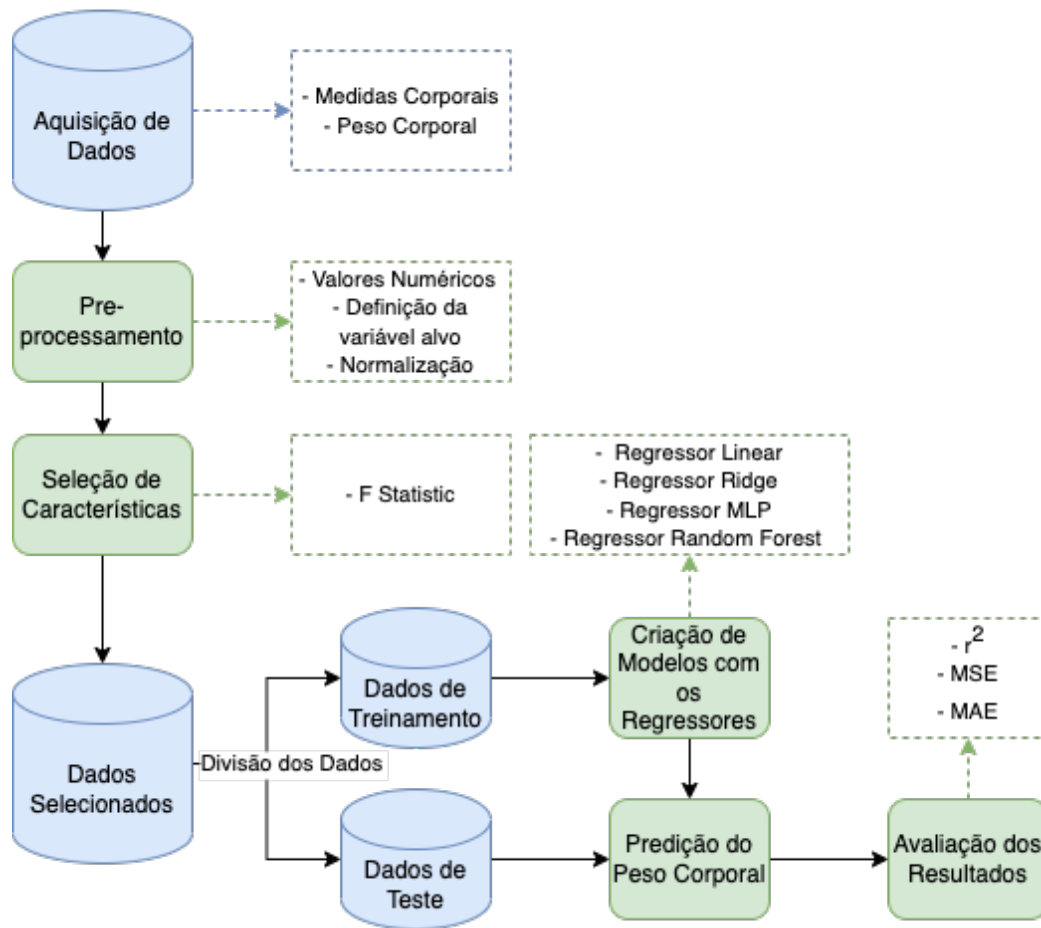


Figura 1: Metodologia proposta para predição de peso em ovinos da raça Santa Inês.

94 Figura 1 apresenta as etapas da metodologia proposta com detalhes de cada  
 95 etapa.

### 96 2.1. Aquisição da Base de Dados

97 Os dados utilizados no estudo pertencem ao projeto "Estudo Genômico  
 98 Aplicado ao Melhoramento Genético de Ovinos Santa Inês para Características  
 99 de Carcaça", aprovado pela Comissão de Ética no Uso de Animais da Univer-

100 sidade Federal do Piauí (CEUA/UFPI) sob nº 340/17, que integra o Instituto  
101 Nacional de Ciência e Tecnologia em Ciência Animal (INCT-CA) do CNPq,  
102 coordenado pela Universidade Federal de Viçosa.

103 Os dados são provenientes de 18 rebanhos manejados na sub-região Meio-  
104 Norte do Brasil (estados do Piauí e Maranhão), referentes a animais regis-  
105 trados junto à Associação Brasileira de Criadores de Ovinos (ARCO), ou  
106 pertencentes ao núcleo de conservação de caprinos e ovinos da Embrapa  
107 Meio-Norte (Campo Maior, Piauí). O banco de dados é composto por regis-  
108 tros de pedigree e fenótipos mensurados entre os anos de 2012 a 2021.

109 A coleta de dados se referiu à medição manual dos animais com o objetivo  
110 de obter: peso corporal (P), Escore de Condição Corporal (ECC), perímetro  
111 da perna (PPerna), altura da cernelha (AC), altura da garupa (AG), com-  
112 primento corporal (CC), altura do peito (AP), perímetro da canela (PC),  
113 perímetro torácico (PT), comprimento da garupa (CGa), e comprimento da  
114 perna (CPerna).

## 115 *2.2. Pré-Processamento*

116 Após a coleta dos dados, foi realizado o pré-processamento que consistiu  
117 em 2 etapas: i) i) a característica de peso foi separada do banco de dados  
118 principal, pois a mesma foi definida como a variável alvo, ou seja, a carac-  
119 terística que será predita. ii) os dados foram normalizados para valores entre  
120 -1 e 1, isso foi feito para evitar que características com valores altos anulassem  
121 outras com valores baixos.

### 122 2.3. Seleção de Características

123 A seleção de características é uma técnica comum usada em *machine*  
124 *learning* para identificar o conjunto de características mais relevantes em um  
125 conjunto de dados [8, 9]. Na etapa de seleção de características, os objetivos  
126 foram os seguintes: i) determinar se é possível obter um subconjunto de  
127 características com uma predição estatisticamente similar quanto utilizando  
128 todos as características; e, ii) verificar a existência de características que não  
129 tem importância na predição de peso.

130 O teste-F foi usado para avaliar a relação entre variáveis de entrada (ca-  
131 racterísticas corporais) e de saída (peso corporal) [8], sendo este uma razão  
132 da variação explicada pelo modelo sobre a variação não explicada. Em uma  
133 análise de regressão linear múltipla com  $k$  variáveis, o teste-F é calculado  
134 como:

$$F = \frac{\frac{SQ_{modelo}}{k}}{\frac{SQ_{residual}}{n-k-1}}, \quad (1)$$

135 onde  $SQ_{modelo}$  é a soma dos quadrados da regressão e  $SQ_{residual}$  é a soma  
136 dos quadrados dos resíduos, e  $n$  é o número de observações. O teste-F é  
137 distribuído como uma distribuição  $F$  com  $k$  graus de liberdade no numerador  
138 e  $n - k - 1$  graus de liberdade no denominador [8].

139 Para selecionar as características mais importantes, o teste-F foi calculado  
140 para cada variável de entrada. As variáveis com um valor de F maior foram  
141 as que mais se relacionam com a variável de saída [8, 10].

### 142 2.4. Predição de Peso

143 Na etapa de predição utilizou-se regressores. A fim de obter o melhor  
144 resultado possível, investigar diferentes possibilidades, e baseado em traba-

145 lhos do estado-da-arte, testou-se os seguintes regressores: Linear [11], Ridge  
146 [12], *MultiLayer Perceptron* [13], e *Random Forest* [14]. No problema abor-  
147 dado neste trabalho tem-se que a variável dependente é o peso corporal, e as  
148 variáveis independentes são as características dos ovinos.

### 149 2.5. Experimentos e Métricas de Avaliação

150 Foram realizados dois conjuntos de experimentos. No primeiro foram  
151 utilizadas todas as características descritas na Seção 2.1 como entrada para  
152 os quatro algoritmos de regressão.

153 O segundo experimento utilizou as melhores características encontradas  
154 na etapa de seleção baseado no teste-F. Nessa etapa foi utilizado o melhor  
155 regressor do primeiro experimento para avaliar as características selecionadas.

156 As métricas mais utilizadas na avaliação de desempenho de modelos  
157 de regressão foram abordadas: Erro Médio Absoluto (MAE), Erro Médio  
158 Quadrático (MSE) [?] e Coeficiente de Concordância ( $r^2$ ) (KRAMER,  
159 2016). A Equação 2, calcula a média dos erros do modelo ao quadrado, ou  
160 seja, diferenças menores são menos importantes, enquanto diferenças maiores  
161 recebem mais peso.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (2)$$

162 onde,  $n$  é o número de observações;  $y_i$  são os valores reais; e,  $\hat{y}_i$  são os valores  
163 preditos pelo modelo.

164 O MAE é uma métrica calculada conforme Equação 3, sendo  $y_i$  o valor  
165 real e  $\hat{y}_i$  o valor predito, cujo a diferença entre o real e o predito é determinada  
166 em módulo.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|. \quad (3)$$

167 De acordo com Zhang (2017), o valor de  $r^2$  ou coeficiente de determinação,  
 168 é calculado a partir da Equação 4, sendo  $y_i$  o valor real,  $\hat{y}_i^2$  o valor predito e  
 169  $\bar{y}$  o valor média para os valores de peso corporal.

$$r^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (4)$$

170 em que,

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i. \quad (5)$$

171 Os experimentos foram realizando utilizando a linguagem de programação  
 172 Python na versão 3, e as bibliotecas Scikit-Learning, Pandas e Numpy. Usou-  
 173 se uma máquina com processador Intel Core i7 3.6GHz e 16GB de memória  
 174 RAM.

### 175 3. Resultados

176 Na Tabela 1, apresenta-se os resultados da estimação do peso corporal  
 177 usando os quatro diferentes regressores: Linear, Ridge, MLP e *Random Fo-*  
 178 *rest*.

179 O regressor Linear alcançou um coeficiente de determinação ( $r^2$ ) médio  
 180 de 0.8075 (0.0504). Isso indica que o modelo foi capaz de explicar aproxima-  
 181 damente 80.75% da variação nos dados de peso corporal. Além disso, o MAE  
 182 médio foi de 4.5284, com um desvio padrão de 0.5627, o que significa que as  
 183 previsões deste modelo tinham, em média, um erro absoluto de aproximada-  
 184 mente 4.53 kg em relação aos valores reais de peso corporal. O MSE médio

Tabela 1: Resultados da estimativa do peso corporal utilizando todas as características e os quatro regressores.

Regressor	$r^2$	MAE	MSE
Linear	<b>0.8075±0.0504</b>	<b>4.5284±0.5627</b>	36.4919±6.7199
Ridge	<b>0.8075±0.0503</b>	4.5296±0.5618	<b>36.4882±6.7052</b>
MLP	0.7906±0.0827	4.5902±0.649	39.5508±12.1502
Random Forest	0.7776±0.0447	4.7952±0.5444	42.2563±4.8225

Em negrito estão os melhores resultados.

185 foi de 36.4919, com um desvio padrão de 6.7199. Isso indica que o modelo  
 186 tem uma tendência a cometer erros maiores em algumas previsões.

187 O Ridge, também obteve um  $r^2$  médio de 0.8075, mas com um desvio  
 188 padrão ligeiramente menor de 0.0503. Isso sugere que ele também foi capaz  
 189 de explicar cerca de 80,75% da variação no peso corporal. O MAE médio  
 190 foi semelhante ao da Regressão Linear, com 4.5296 de MAE médio e 0.5618  
 191 de desvio padrão. O MSE médio foi de 36.4882, com um desvio padrão de  
 192 6.7052, indicando um desempenho comparável ao Regressor Linear.

193 O MLP apresentou um  $r^2$  médio de 0.7906, com um desvio padrão de  
 194 0.0827. Embora tenha explicado um pouco menos da variação nos dados em  
 195 comparação com os regressores Linear e Ridge, ainda conseguiu explicar uma  
 196 porcentagem significativa. No entanto, o MAE médio foi maior, com 4.5902  
 197 e um desvio padrão de 0.649. O MSE médio foi de 39.5508, com um desvio  
 198 padrão de 12.1502, indicando que este modelo tem uma tendência a cometer  
 199 erros maiores e é menos consistente em suas previsões.

200 O *Random Forest* apresentou o menor  $r^2$  médio entre os quatro regres-  
 201 sores, com 0.7776 e um desvio padrão de 0.0447. Isso indica que teve uma

202 capacidade menor de explicar a variação nos dados em comparação com os  
203 outros modelos. Além disso, apresentou o maior MAE de 4.7952, com um  
204 desvio padrão de 0.5444. O MSE foi de 42.2563, com um desvio padrão de  
205 4.8225, sugerindo que este modelo tem uma precisão ligeiramente inferior e  
206 uma tendência a cometer erros maiores em comparação aos demais regresso-  
207 res.

208 A Figura 2 exibe um gráfico de dispersão que compara o peso corporal real  
209 com os pesos estimados pelo modelo de Regressão Linear utilizando todas as  
210 características morfométricas. A linha vermelha representa a reta perfeita,  
211 indicando que quanto mais próximos os pontos de dados estiverem dela, mais  
212 precisa será a predição.

213 No segundo experimento, foi realizada uma análise da correlação e da  
214 importância de cada medida linear na estimação do peso corporal. A Figura 3  
215 apresenta a correlação de Pearson [15] entre as características coletadas. Em  
216 destaque é apresentada a correlação do Peso Corporal (P) com as demais  
217 características. Observa-se que a maior correlação com o P foi o PT.

218 A Tabela 2 apresenta os resultados da predição do peso usando cada  
219 característica morfométrica individualmente com o Regressor Linear, que  
220 no experimento anterior obteve o melhor resultado. Essa tabela apresenta  
221 também a importância de cada medida calculada pelo teste-F.

222 Utilizou-se o cálculo da importância dos atributos com o teste-F para  
223 entender quais atributos ou características têm mais influência na predição  
224 do peso corporal. Essas informações são mostrados também na Figura 4,  
225 onde a importância foi normalizada entre 0 e 1 de acordo com o valor da  
226 maior importância para facilitar a visualização.






Figura 2: Gráfico de dispersão comparando os resultados do peso corporal e os valores previstos usando todos os atributos e Regressor Linear.

227 Com base na análise prévia da importância das características, realizou-se  
228 se um experimento com o propósito de reduzir a quantidade de atributos  
229 necessários para efetuar a predição do peso. Esse experimento adotou uma  
230 abordagem incremental, na qual os atributos foram ordenados de acordo com  
231 sua importância e, em seguida, a regressão foi executada, adicionando gra-  
232 dualmente cada característica ao conjunto de variáveis de entrada do modelo  
233 até que todas as características fossem incluídas. Esse experimento é apre-  
234 sentado na Figura 5.

235 A Figura 6 apresenta os gráficos de dispersão comparando o peso cor-




Figura 3: Correlação de Pearson entre as características. Peso corporal (P), escore de condição corporal (ECC), perímetro da perna (PPerna), altura da cernelha (AC), altura da garupa (AG), comprimento corporal (CC), altura do peito (AP), perímetro da canela (PC), perímetro torácico (PT), comprimento da garupa (CGa), e comprimento da perna (CPerna).

Tabela 2: Resultados da estimativa do peso corporal utilizando cada medida e o regressor Linear e seu respectivo score de importância de acordo com o teste-F.

Medida	$r^2$	MAE	MSE	teste-F*
ECC	0.2950±0.1202	8.7958±0.982	135.9185±17.2857	247.04
PPerna	0.1451±0.0422	10.1035±0.8506	166.3363±18.0126	104.94
AC	0.3111±0.1381	9.0894±0.3487	131.8514±17.9992	394.97
AG	0.3134±0.1322	8.9774±0.3615	131.7206±19.444	395.47
CC	0.3813±0.0781	8.6079±0.3807	120.2074±18.0081	411.81
PC	0.3868±0.0525	8.7351±0.6313	118.9044±11.928	459.39
<b>PT</b>	<b>0.7679±0.061</b>	<b>4.8256±0.6967</b>	<b>44.7275±10.7921</b>	<b>2595.48</b>
CGa	0.0084±0.0336	10.653±0.9114	193.1425±21.7332	35.92
CPerna	0.1315±0.1433	9.9385±0.508	167.9326±24.2417	149.82

\*Todos os valores do teste-F tiveram p-value < 0,01. Escore de condição corporal (ECC), perímetro da perna (PPerna), altura da cernelha (AC), altura da garupa (AG), comprimento corporal (CC), altura do peito (AP), perímetro da canela (PC), perímetro torácico (PT), comprimento da garupa (CGa), e comprimento da perna (CPerna).

236 poral real com os valores previstos pelo modelo de Regressão Linear, utili-  
 237 zando as três melhores características selecionadas com base na Figura 4.  
 238 Observa-se que o padrão do gráfico se assemelha ao obtido quando todas as  
 239 características foram utilizadas (Figura 2), com métricas inferiores, porém,  
 240 similares.

241 A Tabela 3 apresenta estatísticas descritivas para as médias de peso cor-  
 242 poral predito pelo método proposto e o peso corporal observado no banco  
 243 de dados. A análise estatística descritiva revelou que as médias de peso ob-  
 244 servado e predito são semelhantes, como evidenciado pelo teste t. Ambos os




Figura 4: Importância normalizada das medidas morfométricas para a predição de peso vivo. Escore de condição corporal (ECC), perímetro da perna (PPerna), altura da cernelha (AC), altura da garupa (AG), comprimento corporal (CC), altura do peito (AP), perímetro da canela (PC), perímetro torácico (PT), comprimento da garupa (CGa), e comprimento da perna (CPerna).

245 conjuntos de dados apresentaram variabilidades moderadas, com coeficientes  
 246 de variação inferiores a 0,25, sugerindo consistência nas medições. Os inter-  
 247 valos de confiança de 95% para as médias são estreitos, o que indica uma  
 248 precisão razoável das estimativas. No entanto, é importante observar que a  
 249 amplitude do peso observado é maior em comparação com o peso predito,  
 250 indicando uma maior dispersão dos dados.

251 A Tabela 3 é útil para fornecer uma visão geral das estatísticas descritti-  
 252 vas dos dados de peso corporal observado e predito. Ela fornece informações  
 253 sobre a média, variabilidade, incerteza em torno da média e intervalo de con-

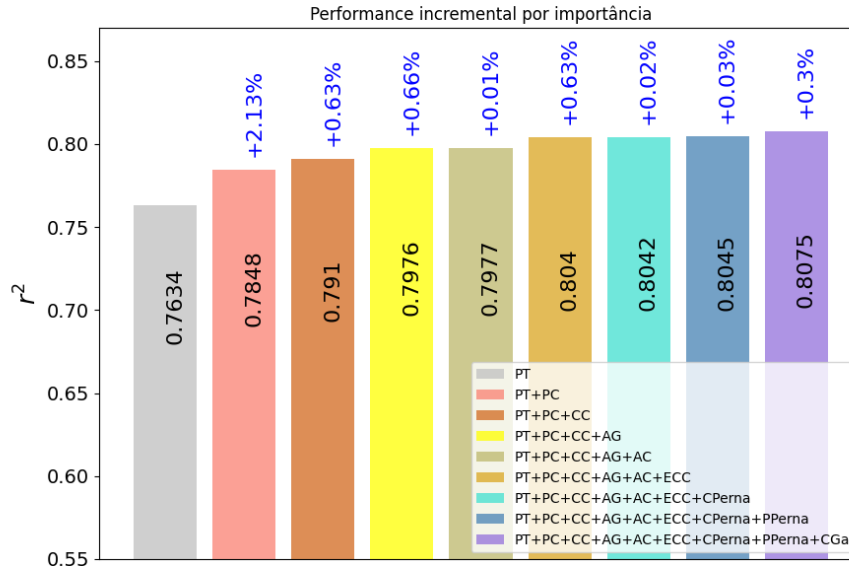




Figura 5: Performance para a predição de peso utilizando as medidas morfométricas de forma incremental. Escore de condição corporal (ECC), perímetro da perna (PPerna), altura da cernelha (AC), altura da garupa (AG), comprimento corporal (CC), altura do peito (AP), perímetro da canela (PC), perímetro torácico (PT), comprimento da garupa (CGa), e comprimento da perna (CPerna).


254 fiança dos dados. Ao comparar as estatísticas entre o "Peso Observado" e  
 255 o "Peso Predito", é possível avaliar o desempenho do método proposto em  
 256 relação aos dados observados e entender a precisão das previsões feitas pelo  
 257 modelo. De forma geral, as estatísticas descritivas sugerem que o método  
 258 proposto para a predição de peso corporal está produzindo resultados razoa-  
 259 velmente precisos, com intervalos de confiança estreitos em torno das médias  
 260 das estimativas.



(a) PT



(b) PT+PC



(c) PT+PC+CC

Figura 6: Resultado para predição de peso utilizando um, dois e três atributos mais importantes. Comprimento corporal (CC), perímetro da canela (PC), perímetro torácico (PT).

Tabela 3: Estatística descritiva para as médias de peso corporal predito pelo método proposto e observada no banco de dados.

Peso	$\hat{\mu}$	CV	EPM	A	$\sigma^2$	IC	
						Inferior	Superior
Observado	57.50a	24.51%	0.56	91.20	199.44	56.39	58.60
Predito	57.34a	22.40%	0.51	73.87	165.29	56.34	58.35

a: médias seguidas de mesma letra não diferem estatisticamente pelo teste t ao nível de 5% de probabilidade.  $\hat{\mu}$ : média. CV: coeficiente de variação. EPM: erro padrão da média; A: amplitude;  $\sigma^2$ : variância amostral. IC: intervalo de confiança.

#### 261 4. Discussão

262 Os resultados do primeiro experimento (Tabela 1) mostram que o regres-  
 263 sor Linear e o regressor Ridge apresentam desempenhos próximos, obtendo  
 264 os maiores valores de  $r^2$  e os menores valores de MAE e MSE. Isso sugere  
 265 que esses dois modelos são os mais eficazes na estimação do peso corporal  
 266 com base nas características morfométricas fornecidas. O MLP, apesar de  
 267 apresentar resultados inferiores, possui resultados próximos aos demais re-  
 268 gressores. O *Random Forest* se mostra um pouco menos eficaz na estimativa  
 269 do peso corporal, com valores inferiores em todas as métricas avaliadas.

270 Analisando o gráfico de dispersão da Figura 2, é perceptível que os da-  
 271 dos seguem um padrão linear, indicando um ajuste adequado ao modelo.  
 272 Esse resultado sugere que o modelo de regressão Linear é apropriado para  
 273 a tarefa em questão e que as características utilizadas possuem uma relação  
 274 significativa com o peso corporal.

275 O experimento apresentado na Tabela 2 concentrou-se na avaliação do  
 276 poder preditivo das características morfométricas individualmente, com es-

277 pecial destaque para PT, PC, CC e AG, quando empregadas individualmente  
278 na regressão Linear para estimar o peso corporal. O PT se destacou como  
279 a mais eficaz na predição do peso corporal, apresentando um coeficiente de  
280 determinação ( $r^2$ ) médio de 0.7679 e o maior valor de importância de acordo  
281 com teste-F. Além disso, PT demonstrou baixos valores de MAE e MSE,  
282 reforçando sua capacidade de proporcionar estimativas precisas do peso cor-  
283 poral quando usado isoladamente.

284 Ainda em relação ao experimento apresentado na Tabela 2, o PC também  
285 mostrou um desempenho sólido, com um  $r^2$  médio de 0.3868. Embora não  
286 tenha atingido o mesmo nível de precisão do PT, seu MAE e MSE foram  
287 relativamente baixos, destacando seu valor na estimativa do peso corporal  
288 individualmente. O CC alcançou um  $r^2$  médio de 0.3813, indicando uma  
289 capacidade razoável de explicar a variação no peso corporal por conta própria.  
290 Seus MAE e MSE foram mais altos do que os de PT e PC. O AG demonstrou  
291 um  $r^2$  médio de 0.3134, sugerindo que esta característica também contribui  
292 para a predição do peso corporal. Seus MAE e MSE foram comparáveis aos  
293 de CC, reforçando sua utilidade no contexto da estimativa de peso corporal.

294 Estas características morfométricas individuais, com destaque para PT,  
295 PC, CC e AG, se mostraram valiosas na predição do peso corporal. A es-  
296 colha criteriosa dessas características desempenha um papel fundamental na  
297 construção de modelos eficazes de estimativa de peso corporal.

298 Para reforçar os resultados da Tabela 2, a Figura 4 permite concluir  
299 que o PT é a característica mais importante, ou seja, ele possui a maior  
300 influência na predição do peso corporal. Esse resultado sustenta a literatura,  
301 onde fitas métricas para estimação de peso foram propostas e algumas são



302 comercializadas. O PC é o segundo atributo mais importante. Embora sua  
303 pontuação seja consideravelmente menor do que o PT, ainda desempenha um  
304 papel crucial na predição. CC, AG e AC possuem importância próxima ao  
305 PC. Isso indica que esses atributos também são relevantes para a previsão do  
306 peso corporal. Os demais atributos possuem pontuações de importância mais  
307 baixas em comparação com os anteriores. Isso sugere que eles contribuem  
308 menos para a precisão da previsão.

309 Em relação ao experimento incremental (Figura 5), identificou-se que uti-  
310 lizando as três características mais relevantes (PT, PC e CC) foi possível al-  
311 cançar um resultado próximo ao resultado utilizando todas as características.  
312 Essa abordagem gradual proporcionou informações valiosas sobre a importância  
313 relativa de cada atributo e permitiu otimizar o desempenho do modelo ao  
314 selecionar um subconjunto mais eficaz de características para a tarefa de  
315 predição.

316 A utilização de um conjunto reduzido de características pode oferecer be-  
317 nefícios significativos, como um modelo mais simples e menos suscetível a  
318 superajuste de dados, além de facilitar a interpretação dos resultados. Por-  
319 tanto, a abordagem de selecionar as características mais importantes pode  
320 ser uma estratégia vantajosa para aprimorar a eficiência e a aplicabilidade  
321 em um ambiente real do modelo de regressão Linear. Essa análise confirma  
322 que a escolha criteriosa das três características (Figura 6) mais relevantes  
323 manteve a tendência geral das predições, mesmo com um número reduzido  
324 de atributos. Embora as métricas possam ser ligeiramente inferiores, a se-  
325 melhança entre os resultados indica que o modelo ainda é capaz de realizar  
326 predições próximas àqueles alcançados com todas as características. A partir

327 dos resultados do nosso estudo, propomos recomendar a Equação 6 utilizando  
328 as medidas PT, PC e CC.

$$P = 10,5969 \times PT + 1,7572 \times PC + 1,8938 \times CC + 64,4069. \quad (6)$$

329 Os resultados de estudos anteriores demonstram que o PT é o preditor  
330 mais preciso e mais simples entre as medidas corporais lineares. Diversos  
331 estudos têm utilizado modelos de regressão baseados em fitas métricas para  
332 medir o peso vivo dos animais de produção. Um objetivo do estudo de [16]  
333 foi encontrar a melhor equação de previsão para o peso dos caprinos da  
334 raça Jumunapari, a equação com o CC e o PT foram as mais adequadas  
335 para a predição do peso vivo. Já no trabalho realizado por [17] observou-se  
336 que, independentemente da idade, os ovinos da raça Karya mostraram altas  
337 correlações fenotípicas entre seu peso e medidas corporais. O modelo de  
338 regressão múltipla desse trabalho apresentou um  $r^2 = 0,79$  utilizando o CC,  
339 e  $r^2 = 0,87$  utilizando CC e PT.

340 Kumar et al. [18] desenvolveram uma escala preditiva do peso vivo de  
341 ovelhas usando a PT e o CC. Os valores de  $r^2$  para animais com mais de  
342 10kg foi de 86,5% e para aqueles com mais de 15kg foi de 83,9%. Conrado  
343 et al. [7] objetivaram em sua pesquisa estimar o peso vivo dos caprinos.  
344 Para isso, utilizou medidas morfométricas quantitativas de caprino da raça  
345 Canindé. O melhor modelo ( $r^2=0,53$ ) utilizou AC, CC e PT. O PT foi a  
346 variável com a maior correlação (0,69) com o peso. A pesquisa de Huma and  
347 Iqbal [19] descreveu um estudo que utilizou uma variedade de algoritmos de  
348 aprendizado de máquina para modelar e prever o peso corporal de ovinos  
349 da raça Balochi no Paquistão. Foram utilizadas medidas relacionadas ao  
350 corpo (comprimento do corpo, perímetro torácico e altura da cernelha) e

351 testiculares (diâmetro escrotal, circunferência escrotal, comprimento escrotal  
352 e comprimento testicular). O melhor resultados de predição ( $r^2=0,916$ ) foi  
353 obtido com o *Random Forest*. É válido destacar que no trabalho em questão  
354 foram utilizados 7 medidas corporais e um conjunto pequeno de amostras  
355 (131) quando comparado com outros trabalhos da literatura.

356 Um estudo [20] realizado com 200 ovinos da raça Texel utilizou regressões  
357 não lineares e lineares (simples e múltiplas) com as seguintes medidas: CC,  
358 PT, AC, e circunferência escrotal. Os resultados mostraram que, indepen-  
359 dentemente do sexo do animal, os modelos que levaram em conta o PT e a  
360 AC foram os melhores para predizer o peso vivo. Essa conclusão foi baseada  
361 nos coeficientes de determinação mais altos, que foram de 0,82 para as fêmeas  
362 e 0,88 para os machos. Resultados similares foram obtidos por [6] e [21], que  
363 utilizando medidas como PT, circunferência abdominal e AG realizaram a  
364 predição de peso vivo em ovinos mestiços da raça Santa Inês.

365 O presente trabalho corrobora com os resultados da literatura, ou seja, o  
366 PT e o CC reproduziram os melhores resultados pela maioria dos trabalhos  
367 correlatos, independente da raça estudada. Além disso, o trabalho proposto  
368 adiciona o PC como uma medida importante para o problema em questão.

## 369 5. Conclusão

370 Os resultados destacaram a eficácia dos algoritmos de regressão Linear e  
371 Ridge. As características PT, PC e CC demonstraram ser as mais relevantes  
372 para essa tarefa, permitindo predições precisas quando usadas em conjunto.

373 Um conjunto reduzido de características pode produzir resultados próximos  
374 aos obtidos com todas as características na predição do peso vivo, simplifi-

375 cando o modelo sem comprometer significativamente sua precisão.

376 É importante notar que este estudo forneceu uma base sólida, mas oportu-  
377 nidades de aprimoramento persistem, como a exploração de técnicas adi-  
378 cionais de seleção de características. Além disso, a aplicabilidade prática  
379 desses modelos deve ser considerada em contextos reais, levando em conta  
380 fatores específicos do campo.

381 Dentre as limitações do presente trabalho, pode-se citar a ausência de  
382 testes em outras raças de ovinos, e a inexistência de uma busca de melhores  
383 parâmetros para os regressores. Tais limitações pode ser utilizadas como  
384 direcionamento para trabalhos futuros.

385 Em última análise, esta pesquisa contribui para a compreensão da esti-  
386 mativa de peso corporal a partir de características morfométricas e oferece  
387 informações valiosas para a seleção de modelos e atributos em aplicações do  
388 mundo real, proporcionando um equilíbrio entre precisão e simplicidade na  
389 estimativa de peso corporal.

## 390 **6. Agradecimentos**

391 O presente trabalho foi realizado com apoio da Coordenação de Aper-  
392 feiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de  
393 Financiamento 001, e do Instituto Nacional de Ciência e Tecnologia em  
394 Ciência Animal (INCT-CA) do CNPq, coordenado pela Universidade Federal  
395 de Viçosa.

396 **Referências**

- 397 [1] FAO, Meat Market Review 2021, Food and Agriculture Organization of  
398 the United Nations, 2022.
- 399 [2] A. Primo, América: Conquista e Colonização: A Fantástica História-  
400 dos Colonizadores Ibéricos e Seus Animais na era do Descobrimento,  
401 Movimento, 2004.
- 402 [3] A. Sabbioni, V. Beretti, P. Superchi, M. Ablondi, Body weight estima-  
403 tion from body measures in cornigliese sheep breed, Italian Journal of  
404 Animal Science 19 (2020) 25–30. doi:10.1080/1828051X.2019.1689189.
- 405 [4] B. M. Martins, A. L. Mendes, L. F. Silva, T. R. Mo-  
406 reira, J. H. Costa, P. P. Rotta, M. L. Chizzotti, M. I. Mar-  
407 condes, Estimating body weight, body condition score, and  
408 type traits in dairy cows using three dimensional cameras and  
409 manual body measurements, Livestock Science 236 (2020)  
410 104054. URL: <https://doi.org/10.1016/j.livsci.2020.104054>.  
411 doi:10.1016/j.livsci.2020.104054.
- 412 [5] X. Song, E. A. Bokkers, P. P. van der Tol, P. W. Groot Koerkamp,  
413 S. van Mourik, Automated body weight prediction of dairy cows  
414 using 3-dimensional vision, Journal of Dairy Science 101 (2018)  
415 4448–4459. URL: <http://dx.doi.org/10.3168/jds.2017-13094>.  
416 doi:10.3168/jds.2017-13094.
- 417 [6] A. Gurgel, G. Difante, J. Emerenciano Neto, J. Santana, J. Dantas,  
418 F. Roberto, N. Campos, A. Costa, Use of biometrics in the prediction

- 419 of body weight in crossbred lambs, *Arquivo Brasileiro de Medicina Ve-*  
420 *terinária e Zootecnia* 73 (2021) 261–264. doi:10.1590/1678-4162-12087.
- 421 [7] V. Conrado, J. Arandas, M. Ribeiro, Modelos de regressão para predição  
422 do peso da raça caniné através de medidas morfométricas, *Archivos de*  
423 *Zootecnia* 64 (2015) 277–280. doi:10.21071/az.v64i247.400.
- 424 [8] T. Hastie, R. Tibshirani, G. James, D. Witten, *An Introduction to Sta-*  
425 *tistical Learning: With Applications in R*, Springer, 2013.
- 426 [9] I. Guyon, A. Elisseeff, An introduction to variable and feature selection,  
427 *Journal of Machine Learning Research* 3 (2003) 1157–1182.
- 428 [10] K. Chen, C. Feng, Z. Chen, X. Zhu, Feature selection with f-statistic  
429 for high-dimensional data: A filter approach, *Computational Statistics*  
430 *& Data Analysis* 128 (2018) 70–85.
- 431 [11] D. C. Montgomery, E. A. Peck, G. G. Vining, *Introduction to Linear*  
432 *Regression Analysis* (4th ed.), Wiley & Sons, 2006.
- 433 [12] A. E. Hoerl, R. W. Kennard, Ridge regression: Biased estimation for  
434 nonorthogonal problems, *Technometrics* 12 (1970) 55–67.
- 435 [13] C. M. Bishop, *Neural Networks for Pattern Recognition*, Oxford Uni-  
436 *versity Press*, 1995.
- 437 [14] L. Breiman, Random forests, *Machine Learning* 45 (2001) 5–32.  
438 doi:10.1023/A:1010933404324.

- 439 [15] D. Freedman, R. Pisani, R. Purves, *Statistics* (international student  
440 edition), Pisani, R. Purves, 4th edn. WW Norton & Company, New  
441 York (2007).
- 442 [16] M. Dige, P. Rout, M. Singh, s. Bhusan, R. Kaushik, G. Gowane, Estima-  
443 tes of genetic parameters for linear body measurements and prediction  
444 of body weight in goat, *Journal of Animal Breeding and Genetics* 139  
445 (2022). doi:10.1111/jbg.12677.
- 446 [17] O. Yilmaz, I. Cemal, O. Karaca, Estimation of mature live weight using  
447 some body measurements in karya sheep, *Tropical animal health and  
448 production* 45 (2012). doi:10.1007/s11250-012-0229-7.
- 449 [18] A. Kumar, P. Mallick, S. Misra, R. C. Sharma, G. Gowane, The  
450 morphometric scale to predict the live weight of malpura sheep in semi-  
451 arid region of rajasthan, *Indian Journal of Animal Research* (2021).  
452 doi:10.18805/IJAR.B-4147.
- 453 [19] Z. Huma, F. Iqbal, Predicting the body weight of balochi sheep using a  
454 machine learning approach, *TURKISH JOURNAL OF VETERINARY  
455 AND ANIMAL SCIENCES* 43 (2019) 500–506. doi:10.3906/vet-1812-23.
- 456 [20] F. Grandis, F. Junior, L. Cunha, C. Dias, E. Ribeiro, C. Constantino,  
457 N. Koritiaki, A. Cestari, Relação entre medidas biométricas e peso  
458 corporal em ovinos da raça texel, *Veterinária e Zootecnia* 25 (2018) 1–8.  
459 doi:10.35172/rvz.2018.v25.57.
- 460 [21] A. Ruchay, V. Kolpakov, V. Kalschikov, K. Dzhulamanov, K. Dorofeev,  
461 Predicting the body weight of hereford cows using machine learning,

462 IOP Conference Series: Earth and Environmental Science 624 (2021)  
463 012056. doi:10.1088/1755-1315/624/1/012056.



## **CAPÍTULO III**

**Avaliação genética para pesos preditos em ovinos a partir de medidas lineares**

# Avaliação genética para peso predito de medidas lineares em ovinos

Lilian Rosalina Gomes Silva<sup>1,2\*</sup> and José Lindenberg Rocha Sarmiento<sup>1†</sup>

<sup>1</sup>Departamento de Zootecnia Tropical, Universidade Federal do Piauí, Bairro Ininga, Teresina, 64049-550, Piauí, Brazil.

<sup>2</sup>Campus de Valença, Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Avenida Joaquim Manuel, Valença, 64300-000, Piauí, Brazil.

\*Corresponding author(s). E-mail(s): [lilianrosalina@ifpi.edu.br](mailto:lilianrosalina@ifpi.edu.br);

Contributing authors: [sarmiento@ufpi.edu.br](mailto:sarmiento@ufpi.edu.br);

†These authors contributed equally to this work.

## Resumo

Este estudo investigou a viabilidade de utilizar pesos preditos baseados em medidas lineares corporais como critério de seleção para o melhoramento genético em ovinos da raça Santa Inês. A análise focou na avaliação genética do peso vivo, explorando a relação entre os pesos observado e predito. Utilizando dados de 18 rebanhos no Meio-Norte do Brasil, os componentes de variância, coeficientes de herdabilidade e acurácias das estimativas genéticas foram calculados para ambas as características de peso. Os resultados demonstraram que tanto o peso observado quanto o predito possuem uma base genética significativa, com coeficientes de herdabilidade moderados, sugerindo um potencial na seleção genética. A correlação genética elevada entre as características indica uma base genética comum, reforçando a viabilidade do peso predito como critério de seleção. No entanto, a correlação de ranking entre os valores genéticos preditos e observados revelou discrepâncias, apontando para uma potencial alteração na seleção ao utilizar o peso predito. Logo, observou-se que em situações onde o peso vivo não puder ser obtido, a utilização do peso predito pode ser uma alternativa, entretanto de menor qualidade. Este estudo contribui para o campo do melhoramento genético ovino, oferecendo informações sobre a aplicabilidade de pesos preditos

em programas de seleção e destacando a importância de modelos preditivos precisos e do entendimento dos mecanismos biológicos que influenciam o crescimento e desenvolvimento em ovinos.

**Keywords:** Avaliação genética, predição de peso, modelo animal, seleção genética

## 1 Introdução

A avaliação genética voltada ao peso vivo em ovinos é essencial para o aprimoramento produtivo dos rebanhos. Com o uso de Diferenças Esperadas nas Progênes (DEPs), criadores podem selecionar ovinos com maior potencial genético para incrementar o peso, um aspecto vital na produção ovina. Esta seleção genética orienta a escolha de animais para acasalamento, buscando gerar descendentes mais pesados e de maior valor comercial. O sucesso da seleção se baseia na acurácia das estimativas genéticas, dependentes da qualidade dos dados e da aplicação correta de modelos estatísticos [1, 2].

Explorar a utilização do peso predito como uma alternativa para minimizar as perdas dos criadores de ovinos que não têm acesso a balanças é uma área que merece estudo. Isso poderia auxiliar na seleção de animais geneticamente superiores para peso corporal. Para isso, segundo [3], é de grande importância o conhecimento dos parâmetros genéticos da característica de interesse, como a herdabilidade e as correlações genéticas, é crucial para o melhoramento genético animal.

A herdabilidade indica a proporção da variação fenotípica de uma característica que é explicada por fatores genéticos [4]. Já as correlações genéticas indicam a associação genética entre duas características [5]. O conhecimento desses parâmetros permite prever valores genéticos de animais, desenvolver índices de seleção mais eficientes e definir as melhores estratégias de acasalamento [5]. Em resumo, os parâmetros genéticos são ferramentas essenciais para o melhoramento genético animal, pois fornecem informações valiosas sobre a herança de características importantes.

O objetivo principal deste estudo foi conduzir uma avaliação genética dos pesos preditos com base em medidas lineares em ovinos da raça Santa Inês, visando determinar a viabilidade de empregar tais pesos como critério de seleção para o aprimoramento genético dessa espécie.

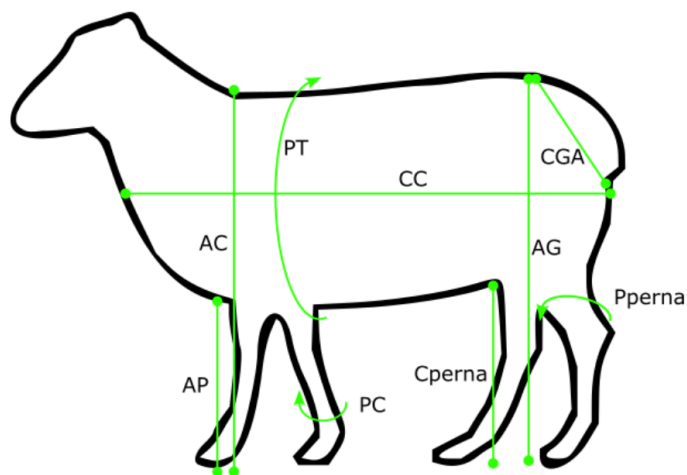
## **2 Material e métodos**

Os dados utilizados pertencem ao projeto “Estudo Genômico Aplicado ao Melhoramento Genético de Ovinos Santa Inês para Características de Carcaça, aprovado pela Comissão de Ética no Uso de Animais da Universidade Federal do Piauí (CEUA/UFPI) sob nº 340/17, que integra o Instituto Nacional de Ciência e Tecnologia em Ciência Animal (INCT-CA) do CNPq, coordenado pela Universidade Federal de Viçosa.

### **2.1 População amostrada**

Os dados utilizados neste estudo são provenientes de 18 rebanhos manejados na sub-região Meio-Norte do Brasil (estados do Piauí e Maranhão), referentes a animais registrados junto à Associação Brasileira de Criadores de Ovinos (ARCO), ou pertencentes ao núcleo de conservação de caprinos e ovinos da Embrapa Meio-Norte (Campo Maior, Piauí). O banco de dados é composto por registros de pedigree e fenótipos mensurados entre os anos de 2012 a 2021.

O conjunto de dados foi constituído por uma matriz de parentesco com 1.863 animais, dos quais 1123 apresentaram informações de pai e mãe, 688 não tinham pais conhecidos e 52 possuíam apenas mãe conhecida, e em um pedigree com profundidade de oito gerações.



**Figura 1** Representação das medidas lineares em ovinos. Perímetro da perna (Pperna), altura da cernelha (AC), altura da garupa (AG), comprimento corporal (CC), altura do peito (AP), perímetro da canela (PC), perímetro torácico (PT), comprimento da garupa (CGA), comprimento da perna (Cperna).

## 2.2 Dados fenotípicos

Neste estudo, foi utilizado o peso vivo de animais adultos aferido em balança mecânica tipo pêndulo, graduada em quilogramas (kg) e o peso predito obtido utilizando medidas lineares.

As informações fenotípicas do banco de dados incluíram: perímetro da perna (Pperna), altura da cernelha (AC), altura da garupa (AG), comprimento corporal (CC), altura do peito (AP), perímetro da canela (PC), perímetro torácico (PT), comprimento da garupa (CGA), e comprimento da perna (Cperna). A Figura ?? apresenta esses dados. Esses dados foram utilizados para prever o peso vivo. Para isso, foi utilizado o teste-F, com o objetivo de selecionar as melhores características para predição do peso. Como resultado da seleção, o CC, o PT e o PC foram utilizados como entrada em um regressor linear para estimar o peso. Nos experimentos realizados foi obtido um coeficiente de determinação ( $r^2$ ) de aproximadamente 0,80. Os pesos estimados com essa metodologia foram utilizados nesse trabalho.

### 2.3 Edição e controle de qualidade dos dados fenotípicos

O procedimento preliminar para edição e consistência dos dados fenotípicos foi realizado com uso do software *SAS OnDemand for Academics*, de modo que foram mantidos animais com informações de sexo, período de coleta, ano de coleta e fazenda. O grupo contemporâneo (GC) foi composto pelos efeitos do sexo do animal (1 = macho e 2 = fêmea), período de coleta (1 = coletas realizadas de janeiro a maio – período chuvoso; e 2 = coletas realizadas de junho a dezembro – período seco), ano de coleta (2012, 2013, 2014, 2017, 2018 e 2022) e fazenda (1 a 18). A idade do animal no momento da coleta foi utilizada como covariáveis (efeito linear).

Após o procedimento para edição e consistência dos dados fenotípicos, apenas observações de grupos contemporâneos com no mínimo quatro animais foram mantidos. Amostras com valores acima ou abaixo de três desvios padrão da média de cada grupo contemporâneo foram removidas. No total, 616 observações de peso observado (PO) e peso predito (PP) foram utilizadas para as análises estatísticas.

### 2.4 Avaliação Genética

Os componentes de (co)variância e parâmetros genéticos necessários para realizar as análises foram estimados com utilização do modelo animal [6]. Para isto, foram utilizados os programas POSTGIBBS1F90 [7]. Para as estimativas da distribuição a posteriori dos componentes de (co)variância e parâmetros genéticos nos para as duas características, foi utilizada uma cadeia de 1.000.000 de ciclos, com descarte inicial de 200.000 (burn-in) e intervalo de amostragem a cada 100 ciclos, totalizando 8.000 amostras para cada análise, a partir das quais as inferências foram realizadas. Para as estimativas de componentes de (co)variância e valores genéticos foi utilizado o modelo:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\boldsymbol{\alpha} + \mathbf{e}, \quad (1)$$

em que:  $\mathbf{y}$  é o vetor de observações para cada característica;  $\beta$  é o vetor de efeitos fixos (grupo contemporâneo e como (co)variável a idade do animal na data da coleta);  $\alpha$  é o vetor de efeitos genéticos aditivos diretos, em que  $\alpha \sim N(0, \mathbf{G})$ , com  $\mathbf{G} = \mathbf{A}\sigma_a^2$ ,  $\mathbf{X}$  é a matriz de incidência dos efeitos fixos;  $\mathbf{Z}$  é a matriz de incidência dos efeitos genéticos aditivos; e  $\mathbf{e}$  é o vetor de efeitos residuais, em que  $\mathbf{e} \sim N(0, \mathbf{R})$ , com  $\mathbf{R} = \mathbf{I}\sigma_e^2$ , em modelos unicaracterística. Para as análises bicaracterísticas, a estrutura de (co)variância entre as características foi modelada como:

$$Var \begin{bmatrix} \alpha \\ e \end{bmatrix} = \begin{bmatrix} \mathbf{A} \otimes \mathbf{G}_0 & 0 \\ 0 & \mathbf{I} \otimes \mathbf{R}_0 \end{bmatrix}, \quad (2)$$

em que,

$$\mathbf{G}_0 = \begin{bmatrix} \sigma_{a1}^2 & \sigma_{a12}^2 \\ \sigma_{a21}^2 & \sigma_{a2}^2 \end{bmatrix}, \quad (3)$$

é a matriz de (co)variância entre as características devido aos efeitos genéticos aditivos de animal;  $\mathbf{A}$  é a matriz de relacionamento genético aditivo; e

$$\mathbf{R}_0 = \begin{bmatrix} \sigma_{e1}^2 & \sigma_{e12}^2 \\ \sigma_{e21}^2 & \sigma_{e2}^2 \end{bmatrix}, \quad (4)$$

é a matriz de (co)variância entre as características devido aos efeitos residuais,  $\mathbf{I}$  é a matriz identidade ( $N \times N$ , em que  $N$  representa o número de observações para cada característica) e  $\otimes$  é o operador do produto Kronecker.

As acurácias dos valores genéticos para análises uni e bicaracterísticas, foram calculadas de forma teórica. O cálculo foi realizado com base nos erros padrão da predição (*Standard Error of Prediction* – SEP) estimados a partir da inversa das equações de modelos mistos, de acordo com a equação proposta que segue:

$$Acc_{ij} = 1 - \sqrt{\frac{PEV_{jj}}{\sigma_{aj}^2}}, \quad (5)$$

em que  $PEV_{jj} = SEP_{ij}^2$ , de modo que  $SEP$  é o erro padrão de predição liberado do animal  $i$  para a característica  $j$  e  $\sigma_{aj}^2$  é a variância genética aditiva da característica  $j$ .

Foram calculadas as correlações de Pearson entre os valores genéticos (EBV) preditos nas distintas análises, apenas com modelo unicaracterística. O cálculo da correlação de Pearson é dado como:

$$p = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)}, \quad (6)$$

em que:  $p$  é o Coeficiente de Correlação de Spearman;  $d_i^2$  é o quadrado da diferença entre dois postos de cada observação; e  $n$  é o número de pares de observações.

O Coeficiente de Correlação de Spearman foi utilizado para investigar as alterações de classificação dos animais com bases nos valores genéticos (EBV). Foram realizados 3 experimentos: unicaracterística com o peso observado, unicaracterística com o peso predito, e bicaracterística.

### 3 Resultados

A Tabela 1 fornece uma visão detalhada das estimativas de componentes de variância e coeficientes de herdabilidade para as características de peso observado e peso predito em ovinos.

As estimativas apresentadas na Tabela 1 refletem os componentes de variância e os coeficientes de herdabilidade para características de peso vivo observado e peso predito em ovinos. Para a característica de peso observado, a variância genética aditiva ( $\sigma_a^2$ ) foi de 45,51 e 48,97 para análise unicaracterística e bicaracterística, respectivamente. Em contraste, a variância do erro ( $\sigma_e^2$ ) é 79,27 e 78,95, enquanto a variância fenotípica ( $\sigma_p^2$ ) foi 124,78 e 127,92, respectivamente. Isso resulta em uma herdabilidade ( $h^2$ ) de 0,36 e 0,38 para análise unicaracterística e bicaracterística, indicando uma influência genética moderada na expressão dessas características.



Na análise bicaracterística, observou-se um aumento significativo na acurácia em comparação com a análise unicaracterística, com ganhos de 5,3% e 20% para peso observado e peso predito, respectivamente. Isso sugere que a inclusão de mais uma característica na análise pode melhorar substancialmente a acurácia das estimativas genéticas. As correlações genéticas aditivas ( $r_a$ ) e fenotípicas ( $r_p$ ) também foram de 0,95 e 0,88, respectivamente.

**Tabela 1** Estimativas de componentes de variância e coeficientes de herdabilidade para características peso vivo observado e peso predito em ovinos.

Característica	$\sigma_a^2$	$\sigma_e^2$	$\sigma_p^2$	$h^2$	Acurácia	Ganho	$r_a$	$r_p$
Unicaracterística								
Peso Observado	45,51	79,27	124,78	0,36	0,19	-	-	-
Peso Predito	33,08	79,36	112,44	0,29	0,15	-	-	-
Bicaracterística								
Peso Observado	48,97	78,95	127,92	0,38	0,20	5,3%	0,95	0,88
Peso Predito	34,3	80,54	114,84	0,29	0,18	20%		

$\sigma_a^2$  é a variância genética aditiva,  $\sigma_e^2$  é a variância do erro,  $\sigma_p^2$  é a variância fenotípica,  $h^2$  é a herdabilidade, Ganho é o aumento (%) entre da acurácia utilizando a análise unicaracterística e bicaracterística,  $r_a$  é a correlação genética aditiva, e  $r_p$  é a correlação genética fenotípica.

A Tabela 2 exibe os valores genéticos preditos e a classificação dos 3% animais superiores com base, respectivamente, no peso observado e no peso predito. Na coluna Ranking 1 observa-se o ranqueamento do peso observado, e na coluna Ranking 2 observa-se a posição do mesmo animal utilizando o peso predito, no ranking do peso observado. Ou seja, o animal 1046 ocupa a primeira posição em ambos os rankings, entretanto o animal 1174 ocupa a segunda posição no ranking utilizando o peso observado, e a terceira posição quando é utilizado o peso predito. Ainda, na Figura 2 é possível observar a relação entre os valores genéticos do peso observado e do peso predito.

A correlação de Pearson entre o peso observado e o peso predito foi de 0,99, indicando uma relação quase perfeita entre as duas características quando consideradas

**Tabela 2** Valores genéticos preditos e ordenamento de 3% dos melhores animais de acordo com o valor genético para as características de peso predito e peso observado.

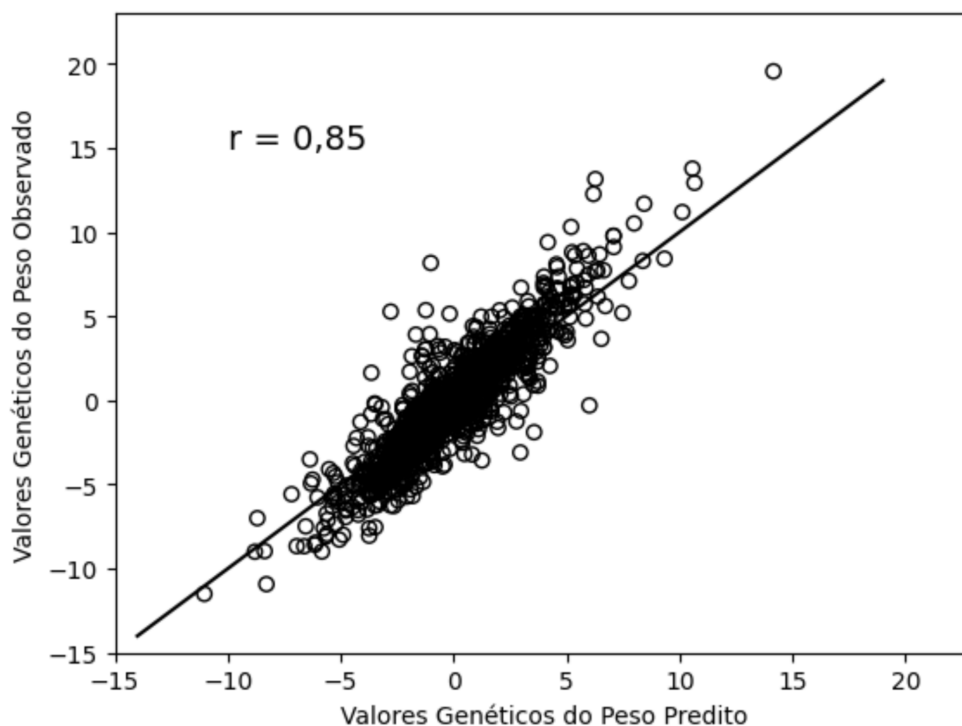
Peso Observado				Peso Predito			
Ranking 1	Animal	VG	Acurácia	Ranking 2	Animal	VG	Acurácia
1	1046	19,55	0,31	1	1046	14,16	0,25
2	1174	13,77	0,34	4	1282	10,66	0,29
3	587	13,15	0,37	2	1174	10,57	0,27
4	1282	12,92	0,36	7	1283	10,12	0,28
5	1170	12,26	0,34	19	1141	9,34	0,34
6	352	11,68	0,39	6	352	8,43	0,33
7	1283	11,19	0,35	20	1228	8,37	0,29
8	899	10,51	0,36	8	899	7,99	0,30
9	1203	10,31	0,36	32	1148	7,76	0,39
10	384	9,78	0,08	76	1145	7,47	0,39
11	592	9,78	0,08	13	1293	7,09	0,28
12	168	9,40	0,23	10	384	7,08	0,06
13	1293	9,11	0,35	11	592	7,08	0,06
14	1511	8,87	0,40	63	169	6,71	0,51
15	1285	8,80	0,41	25	1513	6,65	0,35
16	1412	8,68	0,37	158	1241	6,54	0,31
17	876	8,62	0,41	16	1412	6,47	0,32
18	732	8,60	0,39	49	1135	6,38	0,39
19	1141	8,42	0,40	26	659	6,36	0,13
20	1228	8,29	0,35	3	587	6,27	0,31

VG: valor genético. Ranking 1 corresponde ao ordenamento dos animais de acordo com o VG utilizando o peso observado. Ranking 2 corresponde à posição do mesmo animal no Ranking 1.

linearmente. A correlação de Spearman, que avalia a relação de ordem entre as características, foi de 0,85, sugerindo que há uma forte concordância na classificação dos animais com base em ambas as características.

## 4 Discussão

Os valores de variância genética aditiva para peso observado e peso predito indicam uma base genética significativa para ambas as características, com o peso observado mostrando uma contribuição genética ligeiramente maior. Isso sugere que há uma boa variabilidade genética tanto para o peso observado quanto para o peso predito, uma característica importante para estratégias de melhoramento que visam aumentar o peso corporal. A similaridade nos valores de variância ambiental para ambas as características sublinha a influência dos fatores ambientais e de manejo na expressão



**Figura 2** Valores genéticos obtidos com o peso predito (eixo x) e peso observado (eixo y) e correlação de Spearman entre os dados.

do peso, destacando a importância de otimizar as condições de criação para melhorar o desempenho produtivo.

A variância fenotípica total reflete a variabilidade geral observada nessas características, com valores indicando que o peso observado exibe uma variabilidade ligeiramente maior em comparação com o peso predito. Os coeficientes de herdabilidade foram moderados [8] para ambas as características indicando uma proporção significativa da variabilidade fenotípica que pode ser atribuída a variações genéticas aditivas, oferecendo potencial para a seleção genética.

A acurácia das estimativas, representadas na Tabela 1, reflete a confiabilidade das estimativas de variância e herdabilidade. A acurácia mais baixa para o peso predito (0,15) em comparação com o peso observado (0,19) pode ser devida à complexidade

da modelagem do peso predito, que envolve a integração de diversas variáveis e a potencial incerteza nos dados preditivos.

A comparação entre peso observado e peso predito destaca que, embora ambas as características possuam bases genéticas substanciais, o peso observado pode oferecer uma oportunidade ligeiramente mais favorável para seleção genética devido à sua maior herdabilidade e variância genética aditiva. No entanto, o peso predito também representa uma característica valiosa para o melhoramento, especialmente em contextos onde a medição direta do peso é impraticável ou de custo elevado.

Essas análises são consistentes com estudos que enfatizam a importância de compreender a base genética das características de interesse para maximizar as estratégias de seleção em programas de melhoramento de ovinos[8–10]. Identificar e selecionar animais com base em características com alta herdabilidade e correlações genéticas positivas permite alcançar avanços genéticos significativos, melhorando tanto o desempenho produtivo quanto a eficiência reprodutiva da população ovina.

A Tabela 1 apresenta também as estimativas de componentes de variância e coeficientes de herdabilidade por meio de uma abordagem bicaracterística. Esta abordagem permite uma compreensão mais profunda da arquitetura genética subjacente às características de interesse.

A variância genética aditiva ( $\sigma_a^2$ ) para o peso observado é maior (45,06) em comparação com o peso predito (32,57), indicando uma maior contribuição dos efeitos genéticos aditivos na determinação do peso observado. Por outro lado, na variância ambiental ( $\sigma_e^2$ ), observa-se valores praticamente idênticos para ambas as características (79,64 para peso observado e 79,77 para peso predito), sugerindo que as influências ambientais sobre estas características são similares. Este achado reforça a importância de considerar o manejo e as condições ambientais no desenvolvimento de estratégias de seleção para estas características.

A variância fenotípica total ( $\sigma_p^2$ ) foi ligeiramente maior para o peso observado (124,78) em comparação com o peso predito (112,44). Este resultado pode indicar uma complexidade maior na determinação do peso observado, envolvendo uma interação mais substancial de fatores genéticos e ambientais.

Os coeficientes de herdabilidade ( $h^2$ ) para peso observado (0,36) e peso predito (0,29) indicam proporções moderadas[8] da variância fenotípica que podem ser atribuídas a fatores genéticos. O ganho genético esperado (Ganho) para o peso observado e predito indica o potencial de melhoria genética para cada característica, com valores de 105 e 120, respectivamente, sinalizando uma oportunidade significativa de seleção para aumentar o peso corporal nos ovinos. Covariâncias genéticas, ambientais e fenotípicas entre as características, juntamente com as correlações genéticas, ambientais e fenotípicas, fornecem informações sobre a relação entre o peso observado e predito. Com valores de covariância e correlação de 38,95, 68,68, 107,63 e 0,95, 0,86, 0,88, respectivamente, esses dados sublinham uma forte ligação genética e ambiental entre as características.

A estimativa de correlação genética entre o peso observado e o peso predito em ovinos, avaliada em 0,94, fornece uma evidência robusta da congruência genética entre essas duas características fenotípicas. Esta elevada correlação implica uma forte ligação genética, indicando que os alelos responsáveis pelo aumento do peso observado tendem também a influenciar positivamente o peso predito.

A correlação genética próxima de 1 sugere que quase toda a variação genética que afeta o peso observado também afeta o peso predito, o que pode ser atribuído a uma base genética comum ou a mecanismos biológicos compartilhados que regulam o crescimento e o desenvolvimento em ovinos. Contudo, enquanto a alta correlação genética entre peso observado e peso predito é promissora, é crucial reconhecer que o sucesso de estratégias de melhoramento baseadas nesta correlação também dependerá da acurácia dos modelos preditivos utilizados para estimar o peso predito.

Ambas as características apresentem potencial para seleção genética, tais informações são fundamentais para o desenvolvimento de programas de melhoramento genético direcionados. Além disso, esse experimento reforça a afirmação que é possível realizar a seleção de animais superiores para características de peso utilizando medidas lineares corporais para inferir esse valor.

Em relação ao ranking apresentado na Tabela 2, observa-se uma variação significativa entre os VGs, indicando diferenças na potencial genético entre os animais. A precisão, refletida na acurácia, varia, sugerindo diferenças na confiabilidade das estimativas genéticas. A comparação entre os rankings revela discrepâncias entre os valores genéticos dos animais quando baseados em pesos observados versus preditos, o que ressalta a importância de técnicas de predição precisas na seleção genética. Este experimento ilustra a complexidade e a potencialidade da seleção genética em programas de melhoramento, destacando a necessidade de abordagens rigorosas na estimativa de VG para aprimoramento das características desejadas.

O resultado da correlação de Pearson (0,99) implica que aumentos no peso observado estão fortemente associados a aumentos no peso predito, sugerindo que o peso predito pode ser um indicador eficaz do peso observado. Esta correlação elevada é fundamental para a validação do uso de pesos preditos em estratégias de seleção e avaliação genética, especialmente em situações onde a medição direta do peso pode não ser viável.

A correlação de Spearman (0,85) apresenta um resultado robusto, reforçando a aplicabilidade do peso predito como uma ferramenta confiável para a seleção genética, enfatizando que os animais classificados como mais pesados pelo peso observado tendem a ser consistentemente classificados como mais pesados pelo peso predito.

Na literatura não foram encontrados trabalhos com o mesmo objetivo do proposto. Ou seja, existem trabalhos que realizam a predição do peso vivo utilizando medidas

lineares corporais[11, 12] e trabalhos que fazer análise genética em ovinos[13]. Entretanto o uso de pesos preditos para estimação de componentes de variância e coeficientes de herdabilidade, no melhor de nosso conhecimento, não foram encontrados.

Este estudo apresenta a viabilidade e os benefícios potenciais de incorporar o peso corporal predito em programas de melhoramento em ovinos. No entanto, também alerta para a importância da acurácia em modelos preditivos e a necessidade contínua de entender os determinantes genéticos e ambientais de características economicamente importantes em animais de produção.

## 5 Conclusão

Os experimentos realizado nesse trabalho mostram a viabilidade de se utilizar o peso predito, obtido através de medidas lineares corporais, como um indicador para programas de melhoramento genético. Apesar da correlação genética ser alta, a correlação de ranking foi menor, o que indica mudança na seleção, utilizando PP em relação ao PO. Além disso, a acurácia diminuiu, o que sugere que os valores genéticos obtidos a partir de PP são menos confiáveis do que os valores genéticos obtidos a partir de PO. Pode-se concluir que o uso do PP na seleção genética de ovinos Santa Inês é viável na ausência de balanças, mas que seu uso pode trazer uma confiabilidade menor na seleção dos melhores animais.

A correlação genética elevada entre o peso observado e o peso predito indica uma base genética comum. Contudo, a precisão dos modelos preditivos e a compreensão dos mecanismos biológicos que regulam o crescimento e desenvolvimento são cruciais para o sucesso dessas estratégias de melhoramento.

## Referências

- [1] Gimeno, D. & Ciappesoni, G. Evaluacion genetica poblacional de animales de la corriedale en el uruguay. *Evaluaciones Geneticas Ovinas* **32**, 1–46 (2013).

- [2] Rangel, A. *et al.* Estimation of genetic and phenotypic trends for dairy traits of gyr and guzerá breeds. *Acta Scientiarum. Animal Sciences* **40**, 36685 (2017).
- [3] Cammack, K. M., Leymaster, K. A., Jenkins, T. G. & Nielsen, M. K. Estimates of genetic parameters for feed intake, feeding behavior, and daily gain in composite ram lambs. *Journal of Animal Science* **83**, 777–785 (2005).
- [4] Lôbo, B. N. R. & Lôbo, O. B. M. A. Melhoramento genético como ferramenta para o crescimento e o desenvolvimento da ovinocultura de corte. *Revista Brasileira Reprodução Animal* **31**, 247–253 (2007).
- [5] Bezerra, L. R. *et al.* Residual feed intake: a nutritional tool for genetic improvement. *Tropical Animal Health and Production* **45**, 1649–1661 (2013).
- [6] Henderson, C. *Applications of Linear Models in Animal Breeding* (University of Guelph, 1984). URL <https://books.google.com.br/books?id=3uB6QgAACAAJ>.
- [7] Misztal, I. *et al.* Manual for blupf90 family programs. university of georgia (2018).
- [8] Bennett, G., Pollak, E., Kuehn, L. & Snelling, W. in *Breeding: Animals* (ed. Van Alfen, N. K.) *Encyclopedia of Agriculture and Food Systems* 173–186 (Academic Press, Oxford, 2014). URL <https://www.sciencedirect.com/science/article/pii/B978044452512300228X>.
- [9] Abebe, A. S., Alemayehu, K., Johansson, A. M. & Gizaw, S. Breeding practices and trait preferences of smallholder farmers for indigenous sheep in the northwest highlands of ethiopia: Inputs to design a breeding program. *PLOS ONE* **15**, 1–18 (2020).
- [10] Bernardo, R. Reinventing quantitative genetics for plant breeding: something old, something new, something borrowed, something blue. *Heredity* **125** (2020).



- [11] IQBAL, F. & HUMA, Z. E. Predicting the body weight of balochi sheep using a machine learning approach. *Turkish Journal of Veterinary and Animal Sciences* **43** (2019). URL <http://search/yayin/detay/335942>.
- [12] Gurgel, A. *et al.* Use of biometrics in the prediction of body weight in cross-bred lambs. *Arquivo Brasileiro de Medicina Veterinária e Zootecnia* **73**, 261–264 (2021).
- [13] Dige, M. *et al.* Estimates of genetic parameters for linear body measurements and prediction of body weight in goat. *Journal of Animal Breeding and Genetics* **139** (2022).

## CONSIDERAÇÕES FINAIS

As pesquisas aqui apresentadas reiteram a importância da inovação e precisão na ovinocultura para maximizar a eficiência produtiva e a sustentabilidade econômica do setor. O uso de métodos não invasivos e econômicos para prever o peso vivo dos ovinos, como as medidas lineares corporais, juntamente com análises genéticas detalhadas, são estratégias que se destacam por sua aplicabilidade prática, especialmente em regiões com recursos limitados. As técnicas de melhoramento genético que aproveitam essas medidas e análises genéticas fornecem um caminho promissor para o avanço da seleção ovina, com o potencial de melhorar a produção de carne, lã e outros produtos ovinos.

A integração de abordagens analíticas, como a seleção de características morfométricas e modelos de aprendizado de máquina, demonstra que é possível alcançar estimativas de peso precisas e confiáveis com um conjunto reduzido de medidas. Isso não apenas simplifica o manejo diário, mas também otimiza as estratégias de melhoramento genético e nutricional dos rebanhos. No entanto, a aplicação dessas técnicas deve ser considerada cuidadosamente, dadas as discrepâncias potenciais que podem surgir entre as avaliações de peso preditas e observadas, o que pode afetar os objetivos de seleção a longo prazo.

Portanto, a ovinocultura, impulsionada por essas inovações metodológicas, está bem posicionada para responder às demandas crescentes de um mercado global, mantendo a adaptabilidade e a saúde dos rebanhos. Os resultados desses estudos são um testemunho do poder da ciência aplicada no campo e sua capacidade de informar e transformar práticas tradicionais de manejo em procedimentos baseados em evidências que podem levar a melhorias significativas na produção e reprodução ovina.