

**UNIVERSIDADE FEDERAL DA GRANDE DOURADOS FACULDADE DE
ADMINISTRAÇÃO, CIÊNCIAS CONTÁBEIS E ECONOMIA
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONEGÓCIOS**

**ABORDAGENS DE APRENDIZADO DE MÁQUINA PARA
PREVISÃO DE INDICADORES NA BOVINOCULTURA DE CORTE:
AUXÍLIO EM TOMADA ANTECIPADA DE DECISÕES**

**DOURADOS-MS
2024**

**UNIVERSIDADE FEDERAL DA GRANDE DOURADOS FACULDADE DE
ADMINISTRAÇÃO, CIÊNCIAS CONTÁBEIS E ECONOMIA
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONEGÓCIOS**

**ABORDAGENS DE APRENDIZADO DE MÁQUINA PARA
PREVISÃO DE INDICADORES NA BOVINOCULTURA DE CORTE:
AUXÍLIO EM TOMADA ANTECIPADA DE DECISÕES**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Agronegócios da Universidade Federal da Grande Dourados – Faculdade de Administração, Ciências Contábeis e Economia, para obtenção do Título de Doutora em Agronegócios.

Discente: Nicacia Monteiro de Oliveira.

Orientadora: Luciana Ferreira da Silva.

**DOURADOS-MS
2024**

FICHA CATALOGRÁFICA

Dados Internacionais de Catalogação na Publicação (CIP).

O48a Oliveira, Nicacia Monteiro De

ABORDAGENS DE APRENDIZADO DE MÁQUINA PARA PREVISÃO DE
INDICADORES NA BOVINOCULTURA DE CORTE: AUXÍLIO PARA TOMADA
ANTECIPADA DE DECISÕES. [recurso eletrônico] / Nicacia Monteiro De Oliveira. -- 2025.
Arquivo em formato pdf.

Orientador: Luciana Ferreira da Silva.

Tese (Doutorado em Agronegócios)-Universidade Federal da Grande Dourados, 2024.

Disponível no Repositório Institucional da UFGD em:

<https://portal.ufgd.edu.br/setor/biblioteca/repositorio>

1. Bovinocultura de corte. 2. Indicadores e previsões. 3. Estratégia de manejo. 4. Gestão rural. I.
Silva, Luciana Ferreira Da. II. Título.

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

©Direitos reservados. Permitido a reprodução parcial desde que citada a fonte.

CERTIFICADO DE APROVAÇÃO



Ministério da Educação
Universidade Federal da Grande Dourados
PROPP - Pró-Reitoria de Ensino de Pós-Graduação e Pesquisa



ATA DA DEFESA DE TESE DE DOUTORADO APRESENTADA POR NICACIA MONTEIRO DE OLIVEIRA, ALUNA DO PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONEGÓCIOS, ÁREA DE CONCENTRAÇÃO "AGRONEGÓCIOS E SUSTENTABILIDADE".

Aos doze dias do mês de março do ano de dois mil e vinte e quatro, às treze horas e trinta minutos, em sessão pública, realizou-se na Universidade Federal da Grande Dourados, a Defesa de Tese de Doutorado intitulada **"Abordagens de aprendizado de máquina para a previsão de indicadores na bovinocultura de corte: Auxílio para tomada antecipada de decisão."**, apresentada pela doutoranda Nicacia Monteiro de Oliveira, do Programa de Pós-graduação em Agronegócios, à Banca Examinadora constituída pelos membros: Prof.^a Dr.^a Luciana Ferreira da Silva/UEMS (presidente/orientadora), Prof. Dr. Clandio Favarini Ruviano/UFGD (membro titular interno), Prof. Dr. Paulo Henrique de Oliveira Hoeckel/UFGD (membro titular interno), Prof. Dr. Marcos Paulo Gonçalves de Rezende (membro titular externo), Prof.^a Dr.^a Andréa Roberto Duarte Lopes Souza/UEMS (membro titular externo). Iniciados os trabalhos, a presidência deu a conhecer à candidata e aos integrantes da banca as normas a serem observadas na apresentação da Tese. Após a candidata ter apresentado a sua Tese, os componentes da Banca Examinadora fizeram suas arguições. Terminada a Defesa, a Banca Examinadora, em sessão secreta, passou aos trabalhos de julgamento, tendo sido a candidata considerada APROVADA. Nada mais havendo a tratar, lavrou-se a presente ata, que vai assinada pelos membros da Comissão Examinadora.

Dourados/MS, 12 de março de 2024.

LUCIANA
FERREIRA DA
SILVA:262246
48867

Assinado de forma digital por LUCIANA FERREIRA DA SILVA:26224648867
Dados: 2024.08.06 07:52:05 -04'00'

Prof.^a Dr.^a Luciana Ferreira da Silva
Presidente/orientadora



Documento assinado digitalmente
CLANDIO FAVARINI RUVIANO
Data: 07/08/2024 20:42:23-0300
verifique em <https://validar.iti.gov.br>

Prof. Dr. Clandio Favarini Ruviano
Membro Titular Interno



Documento assinado digitalmente
PAULO HENRIQUE DE OLIVEIRA HOECKEL
Data: 07/08/2024 20:47:25-0300
verifique em <https://validar.iti.gov.br>

Prof. Dr. Paulo Henrique de Oliveira Hoeckel
Membro Titular Interno

Marcos Paulo Gonçalves Rezende

Prof. Dr. Marcos Paulo Gonçalves de Rezende
Membro Titular Externo



Documento assinado digitalmente
ANDREA ROBERTO DUARTE LOPES SOUZA
Data: 20/08/2024 08:50:41-0300
verifique em <https://validar.iti.gov.br>

Prof.^a Dr.^a Andréa Roberto Duarte Lopes Souza
Membro Titular Externo

(PARA USO EXCLUSIVO DA PROPP)

ATA HOMOLOGADA PELO(A) PRÓ-REITOR(A) DE ENSINO DE PÓS-GRADUAÇÃO E PESQUISA DA UFGD
PROPP/UFGD

EPÍGRAFE

Consagre ao Senhor tudo o que você faz, e seus planos serão bem-sucedidos.

Provérbios 16:3

DEDICATÓRIA

Para Minha mãe Edna Gomes Monteiro e meu pai Nivaldo Souza de Oliveira.
Dedico!

AGRADECIMENTOS

Agradeço a Deus pela vida e a Nossa Senhora do Perpétuo Socorro pela interseção e amparo.

Aos meus pais pelo incentivo, apoio, amor e todo empenho e trabalho para minha formação. A minha tia Lenir que me acompanhou na mudança para Dourados e por todas as suas orações e cuidados. A minha irmã Micaeli que sempre esteve com meus pais enquanto eu me dediquei à minha formação. A Minha avó Elizia que me acompanhou e ajudou durante todos esses anos de formação.

A todos os meus familiares e amigos que torceram e rezaram por mim.

A Universidade da Grande Dourados, ao Programa de Pós-graduação em Agronegócios e aos Professores pela oportunidade concedida.

A Professora Doutora Luciana Ferreira Silva por aceitar o desafio de me orientar.

Os meus sinceros agradecimentos aos colegas do PPG Agronegócios das turmas de mestrado e doutorados do ano de 2019 que me receberam e ajudaram com as demandas da pós-graduação e na minha vida. Muito Obrigada!

Aos Professores que fazem parte da minha história, em especial as minhas Professoras da alfabetização Eliete e Cida, ao Professor Doutor Júlio Cesar de Souza que me incentivou a ir para a pós-graduação e ao Professor Doutor Marcos Paulo Gonçalves de Rezende pelos ensinamentos, paciência e prontidão em ajudar nas minhas dificuldades por todos esses anos de vida acadêmica.

O PPG Agronegócios trouxe para a minha vida pessoas muito especiais, que me receberam em suas vidas, casas e famílias: Kauê Felipe, Gabrielli Martinelli, Maria Isabel, Lethicia Dorce, Claudia Quadros.

As amigas Bruna Teodoro, Maria do Carmo, Vanessa Pontes e Livia Mendonça que sempre estiveram presentes com otimismo e incentivo.

E a todos que participaram da minha vida neste período e me ajudaram de alguma forma.

Muito Obrigada

SUMÁRIO

LISTA DE TABELAS	10
LISTA DE FIGURAS	11
RESUMO	14
ABSTRAC	15
LISTA DE ABREVIATURAS	18
I - CONSIDERAÇÕES INICIAIS	19
1.1 Problema e Questões de Pesquisa	20
1.2 Objetivo Geral	20
1.3 Objetivos Específicos	20
1.4 Revisão Bibliográfica	20
1.4.1 Participação da bovinocultura de corte brasileira na indústria animal	20
1.4.2 Indicadores de desempenho na bovinocultura de corte	23
1.4.3 Modelos estatísticos para aplicação nas tomadas de decisões	25
1.4.4 Exemplos da aplicação de machine learning na bovinocultura	27
1.5 Conclusão	28
1.6 Referências Bibliográficas	28
II - COMPARAÇÃO DE MÉTODOS DE APRENDIZADO DE MÁQUINA PARA PREVER BOVINOS NELORE PROPENSOS A DESCARTE COM BASE EM INDICADORES FENOTÍPICOS	33
RESUMO	33
2.1 Introdução	33
2.2 Material e métodos	35
2.2.1 Estrutura metodológica	35
2.2.2 Banco de dados	35
2.2.3 Processamento dos dados	36
2.2.4 Aprendizagem da máquina	37
2.2.5 Estatística adicional	38
2.2.5.1 Comparação de métodos de avaliação de desempenho de validação	38
2.3 Resultados e Discussão	39
2.3.1 Validação cruzada k-fold aplicado nos dados de treinamento	39
2.3.2 Comparação de métodos ML e avaliação do desempenho na previsão de animais a serem descartados baseado no conjunto de dados testes	43
2.3.3 Comparação de métodos ML e avaliação do desempenho na previsão de animais a serem descartados baseado no conjunto de dados de validação externa	46
2.4 Conclusão	57
2.4 Referências Bibliográficas	57
III - APRENDIZAGEM DE MÁQUINA APLICADA A INDICADORES FENOTÍPICOS PARA AGRUPAMENTO DE BOVINOS DE CORTE DE ACORDO COM SEU DESEMPENHO	63
RESUMO	68
3.1 Introdução	63
3.2 Material e métodos	64
3.2.1 Dados	64
3.2.2. Análise estatística	66
3.3 Resultados e Discussão	69
3.4 Conclusão	81
3.5 Referências Bibliográficas	86
IV- CONSIDERAÇÕES FINAIS	87

LISTA DE TABELAS

Tabela 1: Métricas de desempenho dos métodos ML (precisão (Ac) e intervalo de confiança (IC) de 95%, sensibilidade (Se), especificidade (Sp), valor preditivo positivo (VPP), valor preditivo negativo (VPN), kappa (Kp), pontuação F1 e coeficiente de correlação de Matthew (MCC)) no conjunto de validação externa para os seis métodos de aprendizado de máquina (Análise Discriminante Linear (LDA), Árvores de Classificação e Regressão (DTC), Floresta Aleatória (RF) , Rede Neural (NN), Naïve Bayes (NB), Máquinas de Vetores de Suporte (SVM))	46
Tabela 2: Análise descritiva das características fenotípicas e indicadores	64

LISTA DE FIGURAS

Figura 1 - Produtos feitos do bovino	20
Figura 2 - Bovinos Nelore a pasto (A) e a confinamento (B)	21
Figura 3 - Ciclo convencional da bovinocultura de corte	21
Figura 4 - Medição do <i>longissimus dorsi</i> (A) (Marin, 2016); Imagem típica, com a secção transversal do <i>longissimus dorsi</i> (B) (Sainz e Araújo, 2002); Imagem típica da garupa, com o corte longitudinal do <i>Gluteus medius</i> e <i>Bíceps femoris</i> (C) (Sainz e Araújo, 2002).	23
Figura 5 - Processo de aprendizagem da máquina	25
Figura 6 - Árvore de decisão em formato gráfico das opções de decisão	26
Figura 7 - Estrutura do procedimento metodológico	35
Figura 8 - Desenvolvimento da variável binária usada como alvo	37
Figura 9 - Distribuição dos scores de acurácia usando Análise Discriminante Linear (A), Árvores de Classificação e Regressão (B), Floresta Aleatória (C), Rede Neural (D), Naïve Bayes (E) e Máquinas de Vetores de Suporte (F) para cada número de repetições para avaliação cruzada nos dados de treinamento.*1: “critério” crescimento; 2: “critério” reprodução; 3: “critério” carcaça	40
Figura 10 - Comparação do desempenho (valor de acurácia e kappa) de seis métodos de ML (Rede Neural (NN), Máquinas de Vetores de Suporte (SVM), Floresta Aleatória (RF), Árvores de Classificação e Regressão (ACR) e Naïve Bayes (NB)), executados no conjunto de testes. A: “critério” crescimento; B: “critério” reprodução; C: “critério” carcaça. *Linha vermelha representa a média entre os ML	43
Figura 11 - Comparação de calibração de classificadores através de curva de confiabilidade de seis métodos de aprendizado de máquina (Rede Neural (NN), Máquinas de Vetores de Suporte (SVM), Floresta Aleatória (RF), Árvores de Classificação e Regressão (ACR) e Naïve Bayes (NB)), executados no conjunto de testes. A: “critério” crescimento; B: “critério” reprodução; C: “critério” carcaça	45
Figura 12 - Comparação do desempenho (erro falso negativo (diagonal inferior esquerda), erro falso positivo (diagonal superior direita) no conjunto de validação	

externa para os seis métodos de aprendizado de máquina (Análise Discriminante Linear (A), Árvores de Classificação e Regressão (B), Floresta Aleatória (C), Rede Neural (D), Naïve Bayes (E) e Máquinas de Vetores de Suporte (F)) *1: “critério” crescimento; 2: “critério” reprodução; 3: “critério” carcaça 52

Figura 13 - Comparando curvas ROC de seis métodos de ML (Análise Discriminante Linear (A), Árvores de Classificação e Regressão (B), Floresta Aleatória (C), Rede Neural (D), Naïve Bayes (E) e Máquinas de Vetores de Suporte (F)). Em cada parcela, foram relatados a área sob a curva (AUC) e o intervalo de confiança de 95%. *1: “critério” crescimento; 2: “critério” reprodução; 3: “critério” carcaça 54

Figura 14 - Ilustração da aplicação da metodologia de análise para predição dos dados (A) e com indicações das fases (B) 67

Figura 15 - Fluxo demonstrativo da criação dos grupos 68

Figura 16 - Precisão do dos dados reais com o predito. A: Índice de Kleiber aos 365 dias; B: Perímetro escrotal aos 365 dias; C: Índice monentum de peso aos 365 dias; D: Índice monentum de ganho de peso aos 365 dias; E: Índice de Kleiber aos 450 dias; F: Perímetro escrotal aos 450 dias; G: Índice monentum de peso aos 450 dias; H: Índice monentum de ganho de peso aos 450 dias; I: Area de olho de lombo; J: Espessura de gordura subcutânea; K: Espessura de gordura subcutânea na garupa; L: marmoreio 70

Figura 17 - Verifica de probabilidade normalidade para os dados preditivos. A: Índice de Kleiber aos 365 dias; B: Perímetro escrotal aos 365 dias; C: Índice monentum de peso aos 365 dias; D: Índice monentum de ganho de peso aos 365 dias; E: Índice de Kleiber aos 450 dias; F: Perímetro escrotal aos 450 dias; G: Índice monentum de peso aos 450 dias; H: Índice monentum de ganho de peso aos 450 dias; I: Area de olho de lombo; J: Espessura de gordura subcutânea; K: Espessura de gordura subcutânea na garupa; L: marmoreio 72

Figura 18 - Dispersão dos valores reais em relação aos grupos criados com base nos dados preditivos. A: Índice de Kleiber aos 365 dias; B: Perímetro escrotal aos 365 dias; C: Índice monentum de peso aos 365 dias; D: Índice monentum de ganho de peso aos 365 dias; E: Índice de Kleiber aos 450 dias; F: Perímetro escrotal aos 450 dias; G: Índice monentum de peso aos 450 dias; H: Índice monentum de ganho de peso aos 450 dias; I: Area de olho de lombo; J: Espessura de gordura subcutânea; K: Espessura de gordura subcutânea na

garupa; L: marmoreio

74

Figura 19- Importância das variáveis entre as fases para explicar a variação entre os grupos. A: fase 1; B: fase 2; C: fase 3. A: Índice de Kleiber aos 365 dias; B: Perímetro escrotal aos 365 dias; C: Índice monentum de peso aos 365 dias; D: Índice monentum de ganho de peso aos 365 dias; E: Índice de Kleiber aos 450 dias; F: Perímetro escrotal aos 450 dias; G: Índice monentum de peso aos 450 dias; H: Índice monentum de ganho de peso aos 450 dias; I: Área de olho de lombo; J: Espessura de gordura subcutânea; K: Espessura de gordura subcutânea na garupa; L: marmoreio

77

Figura 20 - Biplot entre os grupos discriminados e as variáveis objetivadas na fase 1 (A), fase 2 (B) e fase 3 (C). A: Índice de Kleiber aos 365 dias; B: Perímetro escrotal aos 365 dias; C: Índice monentum de peso aos 365 dias; D: Índice monentum de ganho de peso aos 365 dias; E: Índice de Kleiber aos 450 dias; F: Perímetro escrotal aos 450 dias; G: Índice monentum de peso aos 450 dias; H: Índice monentum de ganho de peso aos 450 dias; I: Área de olho de lombo; J: Espessura de gordura subcutânea; K: Espessura de gordura subcutânea na garupa; L: marmoreio

79

ABORDAGENS DE APRENDIZADO DE MÁQUINA PARA PREVISÃO DE INDICADORES NA BOVINOCULTURA DE CORTE: AUXÍLIO PARA TOMADA ANTECIPADA DE DECISÕES

RESUMO - Uma das atividades com maiores participações na indústria de proteína animal é a bovinocultura de corte. Comumente, o modelo convencional adotado nessa atividade divide-se em cria, recria, e por fim duas direções, a reposição ou terminação. Durante uma fase a outra os animais podem ser descartados ou direcionados a um manejo apropriado para a sua destinação final. Comumente essa decisão baseia-se na interação entre custo de manutenção individual do animal com o seu desempenho para crescimento, capacidade reprodutiva e modelagem corporal como indicativo do rendimento de sua carcaça. A adoção de novas tecnologias de predições na bovinocultura de corte pode auxiliar os produtores rurais a obterem melhores resultados em termos produtivos e econômicos, além de aumentar a transferência e difusão de tecnologia no setor rural, através do desenvolvimento e a integração de machine learning (ML). Nesse sentido, objetivou-se apresentar uma proposta de metodologia usando ML para dar suporte nas decisões na produção de bovino de corte. A primeira parte da tese descreve através de uma revisão bibliográfica, a perspectiva do uso de ML na pecuária. Na segunda parte foi proposto utilizar técnicas de ML para resolver a questão da previsão do desempenho do animal em idades avançadas, o que permitirá descarte de animais antecipadamente. Assim, foi comparado seis métodos diferentes de ML (Análise Linear Discriminante, Naïve Bayes, Árvores de Classificação e Regressão, Máquinas de Vetores de Suporte, Floresta Aleatória e Rede Neural) para identificar o método mais acurado para prever aos 210 dias os animais propensos a descarte aos 450 dias baseados em indicadores fenotípicos. Uma variável alvo binária (0/1) foi criada para representar descarte (1), por meio de 3 índices compostos fenotípicos (ICF) elaborados a partir da combinação de características de crescimento, índice de Kleiber, perímetro escrotal e ultrassonografia de carcaça. Foi considerado animais propensos a descarte aqueles com ICF igual ou inferior a 20%. As acurácias de todos os métodos ficaram acima de 70%. De acordo com diferentes métricas, a Rede Neural e a Floresta Aleatória tiveram o melhor desempenho na previsão. Nesse sentido, os algoritmos de ML se apresentam como uma ferramenta promissora para melhorar a tomada de decisões dos fazendeiros. A análise de ML melhoraria os métodos de descarte ou redirecionamento de manejo de um animal identificado antecipadamente baseado no seu desempenho aos 15 meses. Por fim, a terceira parte da tese aborda uma análise preditiva de dados de modo a classificar grupos de bovinos de acordo com desempenho fenotípico (crescimento, reprodutiva, índice de Kleiber (IK), ultrassonografia e indicadores econômicos) em animais 10% inferiores, grupo intermediário e animais 10% superiores aplicando árvore de classificação e regressão, bem como, análise multivariada. A raiz do erro quadrático médio da previsão foi satisfatório, com máxima de 5,42, e mínima de 0,06. Os valores estimados pela previsão também apresentaram uma normalidade satisfatória para os indicadores. Os grupos criados via machine learning corroborou com desempenho esperado quando analisado seus dados reais. Baseado na árvore geradora mínima, até aos 450 dias, o grupo intermediário ficou mais próximo do grupo inferior 10%, indicando que é possível nessa idade, identificar em modo mais acurado os animais superiores. Já quando

é incluído a ultrassonografia (fase de terminação), o grupo intermediário é mais próximo do grupo superior 10%, ou seja, mais fácil discriminar o grupo inferior. Portanto essa metodologia é promissora para identificar e diferenciar em modo antecipado o desempenho dos animais, o que pode permitir o pecuarista planejar suas estratégias de manejo.

Palavras-chave: Bovinocultura de corte. Indicadores e previsões. Estratégia de manejo. Gestão rural.

MACHINE LEARNING APPROACHES FOR PREDICTING INDICATORS IN BEEF CATTLE: AID FOR EARLY DECISION MAKING.

ABSTRACT – The beef cattle industry is great of the activities with the greatest participation in animal protein. It's common, that the conventional model adopted in this livestock sector is divided into creates, recreates, and next, termination or herd reform. From one phase to another, bovines can be discarded or directed to an appropriate handling for their final destination. This decision is usually based on the interaction between the bovine's maintenance cost and its performance for growth, reproductive capacity, and meat cut or composition as an indication of its carcass yield. The adoption of new prediction technologies in beef cattle farming can help rural producers obtain better results in productive and economic terms, in addition to increasing the transfer and dissemination of technology in the livestock sector, through the development and integration of machine learning (ML). Thus, the aim was to present a proposal for a methodology using ML to support decisions in beef cattle production. The first part of the thesis describes, through a bibliographic review, the perspective of the use of ML in livestock. In the second part, it was proposed that using ML techniques can solve the issue of predicting animal performance pallowrely, allowing premature animal disposal. Thus, six different ML methods were compared (Linear Discriminant Analysis, Naïve Bayes, Tree Decision Classification and Regression, Support Vector Machines, Random Forest, and Neural Network) to identify the most accurate method to predict at 210 days the animals prone to discard at 450 days based on phenotypic indicators. A binary target trait (0/1) was created to represent animal disposal premature (1), using 3 phenotypic composite indices (PCI) created from the combination of growth characteristics, Kleiber index, scrotal perimeter, and carcass ultrasound. Animals with PCI equal to or less than 20% were considered prone to disposal prematurely. The accuracies of all methods were above 70%. According to different metrics, Neural Network and Random Forest methods performed best in prediction. In this sense, ML algorithms present themselves as a promising tool to improve farmers' decision-making. ML analysis would improve culling or redirection methods of handling an animal identified prematurely based on its performance at 15 months. The third part addresses a predictive data analysis to classify groups of cattle according to phenotypic performance (growth, reproductive, Kleiber index (IK), ultrasound, and economic indicators) in animals 10% inferior, intermediate group, and animals 10% superiors applying tree classification and regression, and multivariate analysis. The root mean squared error of the forecast was satisfactory, with a maximum of 5.42 and a minimum of 0.06. The values estimated by the forecast also showed satisfactory normality for the indicators. The groups created via machine learning corroborated the expected performance when analyzing their real data. Based on the minimum spanning tree, up to 450 days, the intermediate group was closer to the lower group by 10%, indicating that it is possible at that age to more accurately identify the higher animals. When ultrasonography is included (termination phase), the intermediate group is closer to the upper 10% group, that is, more facial to discriminate the lower group. Therefore, this methodology is promising to identify and differentiate in advance the performance of the animals, which can allow the cattle rancher to plan his management strategies.

Keywords: BeefCattle. Indicators and forecasts. Management strategy. Rural

management.

LISTAS DE ABREVIATURAS

ANCP = Associação Nacional de Criadores e Pesquisadores GMD = ganho médio diário

IK = índice de Kleiber Im = índice momentum

IM365 = Índice de Momentum aos 365 dias

IGM365 = Índice momentum de ganho de peso aos 365 dias PE365 =

Perímetro escrotal aos 365 dias

IK365 = Índice de Kleiber aos 365 dias IM450 =

IGM450 = Índice momentum de peso aos 450 dias PE450 = Perímetro escrotal aos 450 dias

IK450 = Índice de Kleiber aos 450 dias AOL = Área de olho de lombo

EG = Espessura de gordura subcutânea

EGP = Espessura de gordura subcutânea na garupa MAR = marmoreio

CAPÍTULO 1 – CONSIDERAÇÕES INICIAIS

Em todo o mundo, a bovinocultura de corte possui destaque como fonte de proteína na indústria de carne, além disso, desempenham uma função sustentável ao converter forragem, resíduos de colheitas, além de subprodutos agrícolas e/ou industriais em alimentos de alto valor em termos de qualidade para o consumo humano (Mottet et al., 2017).

Em modelo convencional, a bovinocultura divide-se em um ciclo com três fases: a cria, recria, e por fim duas direções, no qual um percentual dos animais do rebanho retornam para fazer parte da reposição na reprodução, enquanto os demais são conduzidos a fase de engorda e posteriormente o abate. É possível por parte do produtor rural, concentrar em se especializar em uma dessas fases ou fazer a combinações dessas fases. De acordo com Marion (2016), até seis alternativas de ciclo de produção pode serem observadas, iniciando da fase de cria; recria; cria acompanhada de recria; um sistema completo com a cria, recria e engorda; ou concentrado nas últimas fases como a recria seguida da engorda; ou apenas a engorda.

Para sistemas que possuem a cria como uma das fases, a quantidade de bezerro desmamado pode ser considerada fundamental, o que caracteriza a eficiência reprodutiva do rebanho como um dos principais fatores determinante da lucratividade (Diskin e Kenny, 2016). Já na recria, os bezerros desmamados são conduzidos a um sistema de manejo baseado em prévios indicativos de seu uso na próxima fase (abate ou reprodução). Sessim (2016) reporta que tanto nas fases de recria e terminação, o principal objetivo é fazer os bovinos alcançarem o máximo de desenvolvimento músculo e deposição de gordura (Sessim, 2016).

Outro fator importante é que rebanhos com bovinos com alto desempenho para precocidade reprodutiva e fertilidade, são desejáveis, uma vez que possuem maior disponibilidade de animais tanto para venda, como para uso na seleção dos animais que vem a serem usados na reposição. Isso permitirá um maior progresso genético (Rezende et al., 2019). Em geral, um dos maiores impulsionadores da lucratividade em qualquer sistema na bovinocultura de corte é o crescimento do animal e quantidade de kg produzidos por hectare anualmente, além do equilíbrio entre esses dois fatores (Poppi et al., 2018).

Durante uma fase a outra, os animais podem ser descartados ou selecionados para serem destinados a um tipo de manejo mais apropriado para a sua destinação final. Essa decisão é comumente baseada na interação entre custo de manutenção do

animal com as características relacionadas ao seu crescimento, capacidade reprodutiva e modelagem corporal como indicativo do rendimento de sua carcaça.

1.1 Problema e Questão de Pesquisa

Nessas primícias, a capacidade de prever esses indicadores com antecedência pode ajudar os produtores a otimizar suas estratégias para uma melhor processo de seleção dos animais?

Os usos de Machine Learning na produção de bovinos de corte como ferramenta de previsão podem permitir uma maior rentabilidade econômica dentro desse ciclo?

A intensificação dos processos produtivos mediante aplicação de métodos tecnológicos podem contribuir para aumentar a produtividade e a competitividade dos produtores rurais?

1.2 Objetivo Geral

Avaliar uma perspectiva do uso de machine learning como instrumento de apoio a decisões e estratégias de manejos na bovino cultura de corte.

1.3 Objetivos Específicos

- I- Comparar seis métodos diferentes de machine learning para identificar o melhor método de predição para prever aos 210 dias os animais propensos a descarte aos 450 dias, baseado em indicadores fenotípicos de crescimento, reprodutivo e de carcaça.
- II- Classificar através da predição de dados grupos de bovinos de corte de acordo com o seu desempenho fenotípico.

1.4 Revisão Bibliográfica

1.4.1 Participação da bovinocultura de corte brasileira na indústria animal

A produção animal possui participação de destaque para a nutrição e saúde humana em todo o mundo (WHO, 2014), garantindo a subsistência e redução da pobreza (Adesogan et al., 2020), além de contribuir na bioeconomia e sustentabilidade, ao converter forragens, resíduos de colheitas, subprodutos agrícolas e/ou industriais em alimentos de alto valor (Mottet et al., 2017), como por exemplo a carne e leite.

Indicadores estimam que a população mundial está em tendencia crescente, podendo atingir aproximadamente 8,5 bilhões de pessoas já em 2030, 9,7 bilhões em

2050 e 10,4 bilhões entre os próximos 60 anos (década de 2080) (ONU, 2022). Isso reflete na necessidade de intensificar a produção de alimento de modo inteligente, para produzir alimento em quantidade, qualidade e de baixo custo.

Na nutrição humana, a carne como fonte de proteína animal é fundamental para o crescimento e desenvolvimento humano (Higgs, 2000), sendo considerada um dos pilares na evolução da espécie humana, principalmente no desenvolvimento cerebral e intelectual (Pereira e Vicente, 2013). Entre as principais espécies usadas na pecuária, cita-se a bovina, desde carne até produtos lácteos e vestuários por exemplo (Figura 1).

Figura 1 - Produtos feitos do bovino.



Fonte: AgribeeffCO; Tradução: BeefPoint.

Estimativas relatam que 2023, há aproximadamente um bilhão de bovinos (US Department of Agriculture, FAO, 2023). Apenas o Brasil no ano de 2022, produziu aproximadamente 9.7 milhões em toneladas de equivalente de carcaça, possuindo um rebanho de 196 milhões de animais (ABIEC, 2022).

No país, a bovinocultura de corte é baseada comumente em sistema extensivo, ou extensivo seguido de confinamento, realizado tanto com o uso de raças puras como principalmente a Nelore, quanto com o envolvimento de cruzamento entre raças (Figura 2). Em 2021, a bovinocultura de corte representou 8,5% do PIB brasileiro (Cepea, 2021).

Figura 2 - Bovinos Nelore a pasto (A) e a confinamento (B).

A



B




Fonte: Imagens disponíveis na internet.

A bovinocultura de corte brasileira apresenta elevado potencial para produção de carne de qualidade a baixo custo devido a possibilidade da produção em modelo extensivo a pasto (Ferraz e Felício, 2010), com condições climáticas favoráveis e disponibilidade de água (Dick et al., 2021).

Em modelo convencional, a bovinocultura de corte divide-se em um ciclo com três fases: a cria, recria, e por fim duas direções, um pequeno grupo de animais retornam para fazer parte da reposição na reprodução, enquanto o restante dos animais é conduzido a fase de terminação e destinados ao frigorífico (Figura 3).

Figura 3 - Ciclo convencional da bovinocultura de corte.



Fonte: Autor/2023

Na fase de cria, as características indicativas para uso na verificação de desempenho, são a fertilidade de matrizes, maior taxa de desfrute, ganho de peso dos bezerros até a desmama, portanto a percentagem de bezerros desmamados é um dos fatores de maior importância entre os que determinam o lucro ou o prejuízo nessa fase.

Enquanto que na recria é importante desenvolvimento precoce do animal para a

formação de sua estrutura corporal e eficiente quanto a conversão de alimento consumido e produzido em quilo; e pôr fim a engorda onde busca-se o aumento do peso em curto período de tempo e deposição de gordura para acabamento de carcaça. Todavia, durante uma fase à outra, alguns animais podem ser descartados ou destinados a um tipo de manejo mais apropriado para a sua destinação final.

1.4.2 Indicadores de desempenho na bovinocultura de corte

Elaborar novas tecnologias para aumentar a produtividade e rentabilidade dessa atividade é prioridade para acompanhar a crescente necessidade da produção de alimento. Uma das alternativas para alcançar esse objetivo, é o manejo operacional a nível de fazenda.

Advindo de estratégias tomadas pelo pecuarista com base em informações da produtividade do seu rebanho e tendências do mercado. Essa decisão é comumente baseada na interação entre custo de manutenção do animal com as características relacionadas ao seu crescimento, capacidade reprodutiva, eficiência alimentar e modelagem corporal como indicativo do rendimento de sua carcaça.


O conhecimento do crescimento do animal é fundamental descrever a forma sigmoide do padrão de peso de um animal ao longo do tempo (Goldberg e Ravagnolo, 2015), auxiliando no manejo nutricional e na elaboração de programas de seleção e melhoramento genético (Tedeschi et al., 2000).

Segundo Yokoo et al. (2008), um dos maiores interesse dos programas de melhoramento genético, são características de crescimento, uma vez que podem ser facilmente mensuradas e com alta precisão, como o peso ou ganho de peso em determinadas idades do animal. Kaya (2019) reforça que o aumento da lucratividade do negócio depende do acompanhamento regular do peso do animal.

Todavia, tendo em vista as tendências atuais das preferências dos consumidores por melhorias na qualidade dos produtos (Coutinho et al., 2015), tem-se elevado o interesse também em características de carcaça (Figura 4), como por exemplo a área de olho de lombo e espessura de gordura subcutânea que podem ser avaliadas com o uso da ultrassonografia (MacNeil e Northcutt, 2008).

A ultrassonografia apresenta vantagens para a avaliação genética de qualidade de carcaça, uma vez que, permite a análise precoce nos animais sem a necessidade de abate, além de apresentar herdabilidade média – alta (Rezende et al., 2009).

Figura 4 - Medição do *longissimus dorsi* (A) (Marin, 2016); Imagem típica, com a secção transversal do *longissimus dorsi* (B) (Sainz e Araújo, 2002); Imagem típica da garupa, com o corte longitudinal do *Gluteus medius* e *Bíceps femoris* (C) (Sainz e Araújo, 2002).



Fonte: Marin, 2016 e Sainz e Araújo, 2002

O aumento do crescimento corporal associado a redução do consumo de ração é um outro objetivo da bovinocultura de corte, a fim de melhorar a eficiência e a lucratividade dos sistemas de produção (Archer et al., 2004).

Assim, a classificação e/ou identificar os animais de acordo com sua eficiência no consumo de alimentos é desejável para os pecuaristas. Porém, existe uma limitação para esse recolher esse tipo de informação a nível de fazenda, devido à dificuldade de medir o consumo alimentar individual de muitos animais, pois a maioria dos índices adotam essa metodologia como princípio base para estimar sua eficiência (Arthur et al., 2004; Basarab et al., 2011).

Para isso, Kleiber (1936) avaliou o metabolismo energético e formulou um índice que desconsidera medidas individuais de consumo do animal para estimar alternativamente a eficiência alimentar. Esta abordagem pode ser uma ferramenta útil para selecionar os animais com alta eficiência de crescimento em relação ao tamanho do corpo.

De fato, o índice de Kleiber é uma medida da eficiência do crescimento, independentemente do tamanho do corpo (Kleiber, 1961), e como não depende de

informações específicas, esse índice torna-se uma alternativa economicamente viável para estimar a eficiência alimentar dos rebanhos, além de apresentar valores de herdabilidade média a alta (Rezende et al., 2022). Em geral, um valor alto para este índice durante a fase de crescimento e valor baixo na fase de terminação, indica uma maior diluição dos requisitos de manutenção, pois são considerados usuários eficientes de alimentos (Ghafouri-Kesbi et al., 2011).

Baseado nos indicadores descritos acima, entende-se que a maior fonte de receita do produtor é a produção do bezerro até ao abate. Porém na bovinocultura de corte a eficiência reprodutiva das fêmeas é um fator relevante na viabilidade econômica do sistema (Berry et al. 2014), principalmente devido ao custo de manutenção das fêmeas no rebanho (Malhado et al. 2013).

Portanto, a produção e seleção das novilhas e garrotes que serão utilizados na reposição são fundamentais. A reposição deve ser realizada com um controle adequado, pois os touros e as vacas usadas vão contribuir cada um com a metade do material genético de todas as crias.

Além disso, o comercio de animais descartados durante a reposição ou animais entre as fases (cria – recria – engorda), é uma fonte de receita, também muito importante para o produtor. Somado a isso, o aumento da taxa de reposição de novilhas leva a redução da idade média das vacas do sistema e contribui para o progresso genético. No caso dos machos, para eliminar antecipadamente as possíveis perdas oriundas da subfertilidade e infertilidade ou verificar indicadores da fertilidade das gêmeas, principalmente no que diz respeito a idade a puberdade, pode-se avaliar indicativos fenotípicos antes da monta, como por exemplo o perímetro escrotal (Oliveira et al., 2007).

1.4.3 Modelos estatísticos para aplicação nas tomadas de decisões

A criação de ferramentas de previsões que utilizam no mesmo momento diversas características fenotípicas coletadas a partir da fase de cria para gerar indicadores, podem auxiliar na identificação antecipada da melhor estratégia a ser adotada pelo pecuarista. Modelos estatísticos tradicionais e abordagens de aprendizado de máquina mais sofisticadas têm sido usadas para criar preditores de resposta em setores como por exemplo na saúde (Adam et al., 2020, Ding et al., 2018), robótica (Takahashi et al., 2017), climatologia (Fang et al., 2017), aquicultura (Zhou et al., 2018), bioinformática (Mackowiak et al., 2015), pecuária (Romero et al., 2020) e


economia (Athey e Imbens, 2019, Bohanec et al., 2017).

De acordo com Liakos et al. (2018), o aprendizado de máquina surgiu junto com tecnologias de big data e computação de alto desempenho para criar oportunidades para desvendar, quantificar e entender processos intensivos em dados em ambientes operacionais agrícolas. Samuel (1959) define o machine learning como o campo científico que dá às máquinas a capacidade de aprender sem serem estritamente programadas. Normalmente, as metodologias de machine learning envolvem um processo de aprendizagem com o objetivo de aprender com a “experiência” (dados de treinamento) para realizar uma tarefa.

Comumente, um exemplo individual é descrito por um conjunto de atributos, também conhecidos como recursos ou variáveis, no qual um recurso pode ser nominal (enumeração), binário (ou seja, 0 ou 1), ordinal (por exemplo, A+ ou B-) ou numérico (inteiro, número real, etc.) (Liakos et al., 2018). O desempenho do modelo machine learning em uma tarefa específica é medido por uma métrica de desempenho que é aprimorada com a experiência com novas entradas de dados.

Para calcular o desempenho de modelos e algoritmos, vários modelos estatísticos e matemáticos são usados (Liakos et al., 2018). Um exemplo se verifica na figura 5, no qual é possível visualizar o processo de aprendizado, e logo após o modelo treinado pode ser usado para classificar, prever ou agrupar novos exemplos (dados de teste) usando a experiência obtida durante o processo de treinamento.

Figura 5 - Processo de aprendizagem da máquina.




Fonte: Autor/2023.

Os métodos baseados em árvore particionam o espaço do preditor sucessivamente em regiões usando regras de divisão que são resumidas em uma árvore (Wang et al., 2020). O algoritmo subjacente não faz suposições distribucionais,

pode lidar com diferentes níveis de medições em variáveis (Fei et al., 2017), é robusto contra vieses extremos em observações e não tem restrições no número de preditores (Romero et al., 2020). No entanto, é importante ressaltar que a medida que os modelos preditivos aumentam em complexidade, o número de observações necessárias para treinar esses modelos também aumenta.

Em geral, uma árvore de decisão representa um processo de decisão multinível com todas as opções de decisão. Como os caminhos de decisão são representados por ramificações individuais, também é chamado de diagrama de árvore (Figura 6), servindo como um auxílio a decisão, uma vez que o objetivo de uma árvore de decisão é chegar a uma decisão final com base em várias opções de resposta visualizadas para questões concretas (Breiman et al., 1984). A árvore de decisão é estruturada por regras formais, que podem ser seguidas em vários níveis ou opções de resposta, o que auxilia na tomada de decisão

Figura 6 - Árvore de decisão em formato gráfico das opções de decisão.



Fonte: Autor/2023.

1.4.4 Exemplos da aplicação de Machine Learning na pecuária

Na produção de bovinos, estudos vem avançando na utilização de máquinas de aprendizagem, como por exemplo: Lee et al. (2020) que utilizou essa ferramenta para prever o peso da carcaça baseado em medidas corporais, enquanto que Alonso et al. (2015) utilizou o peso para o mesmo objetivo; Cominotte et al. (2020) que utilizaram projeções para estrutura latentes para reduzir a quantidade de fatores em cada uma das fases do crescimento do animal; Nucci et al. (2020) usaram para estimar a gordura da carcaça bovina em fase de terminação.

Alonso et al. (2015) através do desenvolvimento de uma função para a predição do peso de carcaça para bovinos de corte da raça conseguiram prever os pesos das

carcaças 150 dias antes do dia do abate. Olejnik et al. (2022) descreveram que a incorporação de máquina de aprendizagem na avicultura, permitiu detectar de modo automático o peso, bem como os estágios de desenvolvimento do animal, o que possibilitou proceder com um fornecimento adequado de alimento, além de monitorar o efeito desta alimentação sobre o desempenho.

1.5 Conclusão

O uso de máquinas de aprendizagem tem uma tendência linear no setor pecuário, mostrando-se promissor para predizer informações necessárias para antecipar as decisões dos produtores de bovinos de corte.

1.6 REFERÊNCIAS BIBLIOGRÁFICAS

ADAM, G.; RAMPASEK L.; SAFIKHANI, Z.; SMIRNOV, P.; HAIBE-KAINS, B.; GOLDENBERG, A. Machine learning approaches to drug response prediction: challenges and recent progress. **Nature partner journals Precision oncology**, Austin, v.4, n.19, p.4-19, 2020. Doi: <https://doi.org/10.1038/s41698-020-0122-1>.

ADESOGAN, A. T.; HAVELAAR, A. H.; MCKUNE, S. L.; EILITTA, M.; DAHL, G. E. Animal source foods: Sustainability problem or malnutrition and sustainability solution? Perspective matters. **Global Food Security**, Belfest, v. 25, p. 100371, 2020. Doi: <https://doi.org/10.1016/j.gfs.2020.100371>.

ALONSO, J.; VILLA, A.; BAHAMONDE, A. Improved estimation of bovine weight trajectories using Support Vector Machine Classification. **Computers and Electronics in Agriculture**, Amsterdam, v. 110, p. 36–41, 2015. Doi: <https://doi.org/10.1016/j.compag.2014.10.010>.

Associação Nacional de Criadores e Pesquisadores (ANCP). **Características avaliadas**. 2023. Disponível em: <https://www.ancp.org.br/programas/conceitosbasicos/caracteristicas-avaliadas/>. Acesso em 10 de agosto de 2023.

Associação Brasileira das Indústrias Exportadoras de Carne (ABIEC). **Beef Report Perfil da Pecuária no Brasil**. 2022. Disponível em: <http://abiec.com.br/publicacoes/beef-report-2022/>. Acesso em: 10 ago. 2023.

ARCHER, J.A.; BARWICK, S.A.; GRASER, H.U. Economic evaluation of beef cattle breeding schemes incorporating performance testing of young bulls for feed intake. **Australian Journal of Experimental Agriculture**, Melbourne, v. 44, n. 5, p. 393–404, 2004. Doi: <https://doi.org/10.1071/EA02054>.

ALONSO, J.; CASTAÑÓN, Á. R.; BAHAMONDE, A. Support Vector Regression to predict carcass weight in beef cattle in advance of the slaughter. **Computers and Electronics in Agriculture**, Amsterdam, v. 91, p. 116–120, 2013. Doi: <https://doi.org/10.1016/j.compag.2012.12.009>.

BASARAB, J. A.; COLAZO, M. G.; AMBROSE, D. J.; NOVAK, S.; MCCARTNEY, D.; BARON, V. S. Residual feed intake adjusted for backfat thickness and feeding frequency is independent of fertility in beef heifers. **Canadian Journal of Animal Science**, Ottawa, v. 91, n. 4, p. 573–584, 2011. Doi: <https://doi.org/10.4141/CJAS2011-011>.

BERRY, D. P.; WALL, E.; PRYCE, J. E. Genetics and genomics of reproductive performance in dairy and beef cattle. **Animal**, Cambridge, v. 8, n. s1, p. 105–121, 2014. Doi: <https://doi.org/10.1017/S175173111400030X>.

BREIMAN, L.; FRIEDMAN, J.; OLSHEN, R.; STONE, C. **Classification and Regression Trees**. Belmont, CA: Wadsworth International Group, 1984. 358 p.

BOHANEC, M.; KLJAJIČ BORŠTNAR, M.; ROBNIK-ŠIKONJA, M. Explaining machine learning models in sales predictions. **Expert Systems with Applications**, Oxford, v. 71, p. 416–428, 2017. Doi: <https://doi.org/10.1016/j.eswa.2016.11.010>.

COMINOTTE, A.; FERNANDES, A. F. A.; DOREA, J. R. R.; ROSA, G. J. M.; LADEIRA, M. M.; VAN CLEEF, E. H. C. B.; PEREIRA, G. L.; BALDASSINI, W. A.; MACHADO NETO, O. R. Automated computer vision system to predict body weight and average daily gain in beef cattle during growing and finishing phases. **Livestock Science**, Amsterdam, v. 232, p. 103904, 2020. Doi: <https://doi.org/10.1016/j.livsci.2019.103904>.

COUTINHO, C. C.; MERCADANTE, M. E. Z.; JORGE, A. M.; PAZ, C. C. P.; EL FARO, L.; MONTEIRO, F. M. Growth curves of carcass traits obtained by ultrasonography in three lines of Nelore cattle selected for body weight. **Genetics and Molecular Research**, Ribeirão Preto, v. 14, n. 4, p. 14076-14087, 2015. Doi: <http://dx.doi.org/10.4238/2015.October.29.15>.

DELGADO, C.; ROSEGRANT, M.; STEINFELD, H.; EHUI, S.; COURBUIIS, C. Livestock to 2020: the next food revolution. **Outlook on Agriculture**, London, v. 30, n. 1, p. 27–29, 2001. Disponível em: <https://doi.org/10.5367/000000001101292321>.

DICK, M.; SILVA, M. A.; SILVA, R. R. F.; FERREIRA, O. G. L.; MAIA, M. S.; LIMA, S. F.; PAIVA NETO, V. B.; DEWES, H. Environmental impacts of Brazilian beef cattle production in the Amazon, Cerrado, Pampa, and Pantanal biomes. **Journal of Cleaner Production**, Amsterdam, v. 311, p. 127750, 2021. Doi: <https://doi.org/10.1016/j.jclepro.2021.127750>.

DING, M. Q.; CHEN, L.; COOPER, G. F.; YOUNG, J. D.; LU, X. Precision oncology beyond targeted therapy: combining omics data with machine learning matches the majority of cancer cells to effective therapeutics. **Molecular Cancer Research**, Philadelphia, v. 16, n. 2, p. 269–278, 2018. Disponível em: <https://doi.org/10.1158/1541-7786.MCR-17-0358>.

DISKIN, M. G.; KENNY, D. A. Managing the reproductive performance of beef cows. **Theriogenology**, New York, v. 86, n. 1, p. 379-387, 2016. Doi: <https://doi.org/10.1016/j.theriogenology.2016.04.052>.

FANG, K.; SHEN, C.; KIFER, D.; YANG, X. Prolongation of SMAP to Spatiotemporally Seamless Coverage of Continental U.S. Using a Deep Learning Neural Network. *Geophysical Research Letters*, Washington, DC, v. 44, n. 21, p. 11030–11039, 2017. Doi: <https://doi.org/10.1002/2017GL075619>.

FEI, Y.; GAO, K.; HU, J.; TU, J.; LI, W.; WANG, W.; ZONG, G. Predicting the incidence of portosplenomesenteric vein thrombosis in patients with acute pancreatitis using classification and regression tree algorithm. **Journal of Critical Care**, New York, v. 39, p. 124-130, 2017. Doi: <https://doi.org/10.1016/j.jcrc.2017.02.016>.

FERRAZ, J. B. S.; FELICIO, P. E. Production systems – An example from Brazil. *Meat Science*, Oxford, v. 84, n. 2, p. 238-243, 2010. Doi: <https://doi.org/10.1016/j.meatsci.2009.06.009>.

GHAFOURI-KESBI, F.; ABBASI, M. A.; AFRAZ, F.; BABAEI, M.; BANEH, H.; ARPANAHI, R. A. Genetic analysis of growth rate and Kleiber ratio in Zandi sheep. *Tropical Animal Health and Production*, **Edinburgh**, v. 43, n. 6, p. 1153-1159, 2011. Doi: <https://doi.org/10.1007/s11250-011-9816-1>.

GOLDBERG, V.; RAVAGNOLO, O. Description of the growth curve for Angus pasture-fed cows under extensive systems. *Journal of Animal Science*, Champaign, v. 93, n. 9, p. 4285–4290, 2015. Disponível em: <https://doi.org/10.2527/jas.2015-9051>.

GROSSI, D. A.; BERTON, M. P.; VENTURINI, G. C.; PAZ, C. C. P.; BEZERRA, L. A. F.; LOBO, R. B.; MUNARI, D. P. Parâmetros genéticos e fenotípicos de produtividade acumulada e intervalo entre partos em bovinos da raça nelore. In: CONGRESSO BRASILEIRO DE GENÉTICA, 54., 2008, Salvador. **Resumos**. Ribeirão Preto: Sociedade Brasileira de Genética, 2008. p. 1-1.

HIGGS, J. D. The changing nature of red meat: 20 years of improving nutritional quality. **Trends in Food Science & Technology**, Cambridge, v. 11, n. 3, p. 85-95, 2000. Doi: [https://doi.org/10.1016/S0924-2244\(00\)00047-9](https://doi.org/10.1016/S0924-2244(00)00047-9).

KAYA, M. **Determinabilidade do Peso Vivo e do Score de Condição Corporal em Vacas Holandesas em Lactação por meio do Método de Análise Numérica de Imagem**. 2019. 120 f. Tese (Doutorado em Ciência Animal) – Aydın Adnan Menderes University, Aydın, Turquia, 2019.

KLEIBER, M. **Metabolic rate and food utilization as a function of body size**. Columbia, MO, EUA: University of Missouri, 1961. (Boletim de Pesquisa).

LIAKOS, K. G.; BUSATO, P.; MOSHOU, D.; PEARSON, S.; BOCHTIS, D. Machine Learning in Agriculture: **A Review**. **Sensors**, Basileia, v. 18, n. 8, p. 2674, 2018. Doi: <https://doi.org/10.3390/s18082674>.

LEE, D. H.; LEE, S. H.; CHO, B. K.; WAKHOLI, C.; SEO, Y. W.; CHO, S. H.; KANG, T. H.; LEE, W. H. Estimation of carcass weight of hanwoo (Korean native cattle) as a function of body measurements using statistical models and a neural network. **Asian-Australasian Journal of Animal Sciences**, Seul, v. 33, n. 10, p. 1633–1641, 2020. Doi: <https://doi.org/10.5713/ajas.19.0573>.

LÔBO, R. B. **Programa de melhoramento genético da raça Nelore**. 2. ed. Ribeirão Preto: Universidade de São Paulo, 1992.

LIU, F. T.; TING, K. M.; ZHOU, Z. H. Isolation Forest. In: IEEE INTERNATIONAL CONFERENCE ON DATA MINING, 8., 2008, Pisa. **Anais**. Pisa, Itália: IEEE, 2008. p. 413-422. Doi: <https://doi.org/10.1109/ICDM.2008.17>.

MACNEIL, M. D.; NORTHCUTT, S. L. National cattle evaluation system for combined analysis of carcass characteristics and indicator traits recorded by using ultrasound in Angus cattle. **Journal of Animal Science**, Champaign, v. 86, n. 10, p. 2518-2524, 2008. Doi: <https://doi.org/10.2527/jas.2008-1065>.

MALHADO, C. H. M.; MALHADO, A. C. M.; MARTINS FILHO, R.; CARNEIRO, P. L. S.; PALA, A.; CARRILLO, J. A. Age at first calving of Nellore cattle in the semi-arid region of northeastern Brazil using linear, threshold, censored and penalty models. **Livestock Science**, Amsterdã, v. 154, n. 1-3, p. 28-33, 2013. Doi: <https://doi.org/10.1016/j.livsci.2013.02.020>.

MARIN. **Ecografía de carne en la res bovina**. 2016. Disponível em: <https://www.interempresas.net/Industria-Carnica/Articulos/151379-Ecografia-de-carne-en-la-res-bovina.html>. Acesso em: 10 ago. 2023.

MARION, J. C. **Contabilidade rural: contabilidade agrícola, contabilidade da pecuária, imposto de renda pessoa jurídica**. 14. ed. São Paulo: Atlas, 2016.

MACKOWIAK, S. D.; ZAUBER, H.; BIELOW, C.; THIEL, D.; KUTZ, K.; CALVIELLO, L.; MASTROBUONI, G.; RAJEWSKY, N.; KEMPA, S.; SELBACH, M.; OBERMAYER, B. Identification and analysis of conserved small ORFs in animals. **Genome Biology**, Londres, v. 16, n. 1, p. 179, 2015. Doi: <https://doi.org/10.1186/s13059-015-0740-z>.

MOTTET, A.; HAAN, C.; FALCUCCI, A.; TEMPIO, G.; OPIO, C.; GERBER, P. Livestock: On our plates or eating at our table? A new analysis of the feed/food debate. **Global Food Security**, Amsterdã, v. 14, p. 1-8, 2017. Doi: <https://doi.org/10.1016/j.gfs.2017.01.001>.

NUCCI, H. H. P.; ISHII, R. P.; COSTA GOMES, R.; COSTA, C. S.; FEIJÓ, G. L. D. **Classification of Carcass Fatness Degree in Finishing Cattle Using Machine Learning**. p. 519-535. 2020. In: GERVASI, O.; MURGANTE, B.; MISRA, S.; GARAU, C.; BLECIC, I.; IANIAR, D.; APDUHAN, B. O.; ROCHA, A. M. A. C.; TARATINO, E.; TORRE, C. M.; KARACA, Y. Computational Science and Its Applications – ICCSA 2020. Cham: Springer. Doi: https://doi.org/10.1007/978-3-030-58814-4_38.

OLIVEIRA, M. M. D.; ROTA, E. D. L.; DIONELLO, N. J. L.; AITA, M. F. Herdabilidade e correlações genéticas do perímetro escrotal e idade ao primeiro parto com características produtivas em bovinos de corte: revisão. **Revista Brasileira de Agrociência**, Pelotas, v. 13, n. 2, p. 141-146, 2007.

OLEJNIK, K.; POPIELA, E.; OPALINSKI, S. Emerging Precision Management Methods in Poultry Sector. **Agriculture**, Basileia, v. 12, n. 5, p. 718, 2022. Disponível em:

<https://doi.org/10.3390/agriculture12050718>.

Organização das Nações Unidas (ONU). **World Population to Reach 8 Billion**. 2022. Disponível em: <https://news.un.org/en/story/2022/07/1122272>.

PEREIRA, P. M. C. C.; VICENTE, A. F. R. B. Meat nutritional composition and nutritive role in the human diet. **Meat Science**, Oxford, v. 93, n. 3, p. 586-592, 2013. Doi: <https://doi.org/10.1016/j.meatsci.2012.09.018>.

POPPI, D. P.; QUIGLEY, S. P.; SILVA, T. A. C. C.; MCLENNAN, S. R. Challenges of beef cattle production from tropical pastures. **Revista Brasileira de Zootecnia**, Brasília, v. 47, p. e20160419, 2018. Doi: <https://doi.org/10.1590/rbz4720160419>.

REZENDE, F. M.; FERRAZ, J. B. S.; GROENEVELD, E.; MOURÃO, G. B.; BONIN, M. N.; OLIVEIRA, P. S.; ELER, J. P. **Estimation of genetic and phenotypic parameters for meat and carcass trait in Nellore bulls**. In: ANNUAL MEETING OF THE EUROPEAN FEDERATION OF ANIMAL SCIENCE, 60., 2009, Barcelona.

REZENDE, M. P. G.; MALHADO, C. H. M.; BIFFANI, S.; CARNEIRO, P. L. S.; BOZZI, R. Genetic diversity derived from pedigree information and estimation of genetic parameters for reproductive traits of Limousine and Charolais cattle raised in Italy. **Italian Journal of Animal Science**, Bologna, v. 19, n. 1, p. 762-771, 2020. Doi: <https://doi.org/10.1080/1828051X.2020.1794354>.

REZENDE, M. P. G.; MALHADO, C. H. M.; BIFFANI, S.; CARRILLO-TABAKMAN, J. A.; FABBRI, M. C.; CROVETTI, A.; CARNEIRO, P. L. S.; BOZZI, R. Heritability and genetic correlation of body weight and Kleiber ratio in Limousin and Charolais beef cattle breeds. **Animal**, Cambridge, v. 16, n. 6, p. 100528, 2022. Doi: <https://doi.org/10.1016/j.animal.2022.100528>.

ROMERO, M. P.; CHANG, Y. M.; BRUNTON, L. A.; PARRY, J.; PROSSER, A.; UPTON, P.; REES, E.; TEARNE, O.; ARNOLD, M.; STEVENS, K.; DREWE, J. A. Decision tree machine learning applied to bovine tuberculosis risk factors to aid disease control decision making. **Preventive Veterinary Medicine**, Amsterdam, v. 175, p. 104860, 2020. Doi: <https://doi.org/10.1016/j.prevetmed.2019.104860>.

ROBERTS, A. J.; PETERSEN, M. K.; FUNSTON, R. N. Can we build the cowherd by increasing longevity of females? **Journal of Animal Science**, Champaign, v. 93, n. 9, p. 4235-4243, 2015. Doi: <https://doi.org/10.2527/jas.2014-8784>.

SAMUEL, A. L. Some Studies in Machine Learning Using the Game of Checkers. **IBM Journal of Research and Development**, New York, v. 44, n. 1.2, p. 206–226, 1959. (Reimpressão de 2000). Doi: <https://doi.org/10.1147/rd.441.0206>.

SAINZ, R. D.; ARAÚJO, F. R. C. Uso de tecnologias de ultrassom no melhoramento do produto final carne. In: CONGRESSO BRASILEIRO DAS RAÇAS ZEBUÍNAS, 5., 2002, Uberaba. **Anais**. Uberaba: ABCZ, 2002.

SESSIM, A. G. **Análise econômica de sistemas de produção de bovinos de corte na região do Pampa do Rio Grande do Sul**. 2016. 104 f. Dissertação (Mestrado em

Zootecnia) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2016.

TAKAHASHI, K.; KIM, K.; OGATA, T.; SUGANO, S. Tool-body assimilation model considering grasping motion through deep learning. **Robotics and Autonomous Systems**, Amsterdam, v. 91, p. 115-127, 2017. Doi: <https://doi.org/10.1016/j.robot.2017.01.006>.

TEDESCHI, L. O.; BOIN, C.; NARDON, R. F.; LEME, P. R. Estudo da curva de crescimento de animais da raça Guzerá e seus cruzamentos alimentados a pasto, com e sem suplementação: 1. Análise e seleção das funções não-lineares. **Revista Brasileira de Zootecnia**, Viçosa, v. 29, n. 2, p. 630-637, 2000. Doi: <https://doi.org/10.1590/S1516-35982000000200037>.

WANG, Y.; ZHAO, Y.; THERNEAU, T. M.; ATKINSON, E. J.; TAFTI, A. P.; ZHANG, N.; AMIN, S.; LIMPER, A. H.; KHOSLA, S.; LIU, H. Unsupervised machine learning for the discovery of latent disease clusters and patient subgroups using electronic health records. **Journal of Biomedical Informatics**, Amsterdam, v. 102, p. 103364, 2020. Doi: <https://doi.org/10.1016/j.jbi.2019.103364>.

WHO. World Health Organization. **World health assembly global nutrition targets 2025: stunting policy brief**. Genebra: WHO, 2014. Disponível em: https://apps.who.int/iris/bitstream/handle/10665/149019/WHO_NMH_NHD_14.3_eng.pdf. Acesso em: 10 ago. 2023.

ZHOU, C.; LIN, K.; XU, D.; CHEN, L.; GUO, Q.; SUN, C.; YANG, X. Near infrared computer vision and neuro-fuzzy model-based feeding decision system for fish in aquaculture. **Computers and Electronics in Agriculture**, Amsterdam, v. 146, p. 114–124, 2018. Disponível em: <https://doi.org/10.1016/j.compag.2018.01.019>.

YOKOO, M. J.; ALBUQUERQUE, L. G.; LÔBO, R. B.; BEZERRA, L. A. F.; ARAUJO, F. R. C.; SILVA, J. A. V.; SAINZ, R. D. Genetic and environmental factors affecting ultrasound measures of longissimus muscle area and backfat thickness in Nelore cattle. **Livestock Science**, Amsterdam, v. 117, n. 2-3, p. 147-154, 2008. Disponível em: <https://doi.org/10.1016/j.livsci.2007.12.008>.

CAPÍTULO 2 – COMPARAÇÃO DE MÉTODOS DE APRENDIZADO DE MÁQUINA PARA PREVER BOVINOS NELORE PROPENSOS A DESCARTE COM BASE EM INDICADORES FENOTÍPICOS

Análise preditiva para decisões estratégicas na bovinocultura de corte

Resumo - A bovinocultura em seu ciclo completo divide-se em cria, recria e reposição ou terminação. Durante essas fases, animais podem ser descartados e/ou direcionados a um manejo apropriado, uma vez que os lucros dos pecuaristas estão geralmente ligados ao desempenho do seu rebanho. Utilizar técnicas de *machine learning* (ML) podem auxiliar na previsão do desempenho do animal em idades avançadas, viabilizando estratégias de controles de perdas financeiras. Assim, objetivou-se comparar seis métodos diferentes de ML (Análise Linear Discriminante, Naïve Bayes, Árvores de Classificação e Regressão, Máquinas de Vetores de Suporte, Floresta Aleatória e Rede Neural) para identificar o método mais acurado para prever aos 210 dias os animais propensos a descarte aos 450 dias. Uma variável alvo binária (0/1) foi criada para representar descarte (1), por meio de três índices compostos fenotípicos (ICF), elaborados a partir da combinação de características de crescimento, índice de Kleiber, perímetro escrotal e ultrassonografia de carcaça. Foram considerados animais propensos a descarte aqueles com ICF igual ou inferior a 20%. As acurácias de todos os métodos ficaram acima de 70%, mas de acordo com diferentes métricas, a Rede Neural e a Floresta Aleatória tiveram o melhor desempenho na previsão. A análise de ML melhora os métodos de descarte ou redirecionamento de manejo de um animal identificado antecipadamente baseado no seu desempenho aos 15 meses, apresentando-se como uma ferramenta promissora para melhorar a tomada de decisão dos fazendeiros.

Palavras-chave: Análise preditiva. Bovinos. Desempenho. Fenótipo. Gestão rural. Machine learning. Previsão.

2.1 Introdução

A bovinocultura de corte em modelo convencional divide-se em cria, recria, e por fim duas direções, em que um grupo de animais podem ser destinados a

reposição do rebanho, enquanto os demais serão conduzidos a fase de terminação e abate. Todavia, durante essas fases, animais podem ser descartados e/ou direcionados a um manejo apropriado, uma vez que os lucros dos pecuaristas estão geralmente ligados ao adequado desempenho do seu rebanho.

Utilizar técnicas de *machine learning* (ML) pode ser uma abordagem interessante para resolver a questão da previsão do desempenho do animal em idades avançadas, uma vez que algoritmos de aprendizado de máquina são métodos baseados em dados que podem aprender padrões a partir de dados históricos que podem então ser usados para prever casos futuros (Shahinfar et al., 2020). Em geral, os modelos de ML são robustos contra vieses extremos em observações e não tem restrições no número de preditores (Romero et al., 2020), dados faltantes e/ou distribuídos de forma não normal, o que é bastante comum em dados obtidos de fazendas comerciais.

Nesse sentido, o ML pode trazer resultados que permitirão criar estratégias de controles de perdas financeiras, uma vez que é acelera a tomada de decisão (Hakem et al., 2022), através da possibilidade de usar algoritmos de classificação que descreverá antecipadamente animais com baixos desempenhos e propensos a serem descartados.

Além disso, o mesmo conceito do uso para descarte (animais com baixos desempenho em relação aos contemporâneos) podem também ser usado como indicativo de presença de alguma anomalia e/ou doença (Frigo et al., 2010), ou seja, diferentes direções podem ser exploradas para resolução de problemas através da ML.

Modelos estatísticos de ML têm sido usadas na bovinocultura de corte, como na predição do peso da carcaça da carne bovina antes do abate (Alonso et al., 2013; Miller et al., 2019) ou peso corporal (Ruchay et al., 2021, Xiong et al., 2023) e estimação da gordura e/ou qualidade da carcaça bovina em fase de acabamento (Nucci et al., 2020, Lee et al., 2020, Shahinfar et al., 2020).

Em geral, ML é considerado uma ferramenta promissora para melhorar os sistemas de apoio à decisão dos fazendeiros e já foi aplicado em diferentes áreas da bovinocultura como comportamento, alimentação, gestão, fisiologia e reprodução (Cockburn, 2020).

Todavia, não foi encontrado, até o momento na literatura, uma abordagem

em torno de animais propensos a descarte baseado em indicadores fenotípicos, informação essa de relevância econômica. Assim, objetivou-se comparar seis métodos diferentes de ML (Análise Discriminante Linear (LDA), Árvores de Classificação e Regressão (DTC), Floresta Aleatória (RF), Rede Neural (NN), Naïve Bayes (NB), Máquinas de Vetores de Suporte (SVM)) para predição aos 210 dias de animais propensos a descarte aos 450 dias, baseados em indicadores fenotípicos de crescimento, reprodução e carcaça.

2.2 Material e métodos

2.2.1 Estrutura metodológica

A estrutura metodológica empregada foi distribuída em 4 etapas: coleta de dados, processamento de dados, aprendizado de máquina e estatística adicional para validação dos modelos com informações externas (Figura 7).

Figura 7 – Estrutura do procedimento metodológico



Fonte: Autor/2024

2.2.2 Banco de dados

Utilizou-se um banco de dados inicial com 18716 bovinos machos puro de origem da raça Nelore coletado via Associação Nacional de Criadores e Pesquisadores (ANCP, 2023). As variáveis de input utilizadas como indicadores fenotípicos foram: indicador de crescimento: pesos e ganhos médios diários de pesos para as idades ajustadas aos 120, 210 e 450 dias, indicador reprodutivo: perímetro escrotal aos 450 dias; indicador de eficiência energética: proporção de Kleiber (Kleiber, 1936) para as idades 210 e 450 dias, usando a seguinte equação:

$$IK_i = \frac{GMD_j}{Peso_k^{0,75}}$$

Onde: IK_i é o índice de Kleiber na idade i , o GMD é o ganho médio diário estimado entre o tempo a e o tempo b e $Peso^{0.75}$ é o peso metabólico;

indicador de qualidade de carcaça: ultrassonografia da área de olho de lombo (AOL), espessura de gordura subcutânea (EG) e espessura de gordura subcutânea na garupa (EGP8).

Foi também considerado nas análises os efeitos de ano e estação de nascimento e idade em classe da vaca ao parto, idade na avaliação da ultrassonografia da carcaça no qual apenas informações pertencentes a classes de efeitos com ao menos 30 registros foram mantidas.

2.2.3 Processamento dos dados


Todo o procedimento de edição de dados, aprendizagem de máquina e demais análises posteriores foram feitas utilizando algoritmos implementados em *Python* 3.8.10. Hipotiza-se que o uso combinado de diferentes indicadores fenotípicos retrataria melhor a decisão do pecuarista além de poder ter mais sucesso na detecção dos animais com alta probabilidade de haver desempenho bem abaixo do rebanho e consequentemente serem descartados.

Nesse sentido, inicialmente foi criado a variável alvo (“critério”) através da simulação da decisão dos criadores para descarte de animais. Foram simulados 3 “critérios” de índices compostos em modo empíricos. Os pesos atribuídos para as características fenotípicas foram:

- 1) $\text{peso} * 60 + \text{ganho de peso} * 20 + \text{eficiência energética} * 15 + \text{perímetro escrotal} * 5$, ponderando o crescimento.
- 2) $\text{peso} * 10 + \text{ganho de peso} * 30 + \text{eficiência energética} * 5 + \text{perímetro escrotal} * 50$, ponderando capacidade reprodutiva.
- 3) $\text{peso} * 25 + \text{ganho de peso} * 5 + \text{eficiência energética} * 5 + \text{perímetro escrotal}$.

Para cada índice proposto foi criado uma variável binária a partir da discriminação de animais presente no quadrante 20% inferior (descarte), enquanto os demais foram considerados como animais a serem mantidos no rebanho (Figura 8).

Figura 8 – Desenvolvimento da variável binária usada como alvo.



Os modelos de ML concentram-se em previsões e não assumem uma distribuição funcional dos dados. Por esse motivo, decidimos inicialmente realizar a análise sem transformação de dados, uma vez que todas as nossas características possuem distribuição normal.

Após estes testes preliminares, nenhuma transformação foi necessária, apenas foi realizado um ajuste com a exclusão de 10% de informações na linha intermediária entre 0/1, devido ao alto percentual de falsos positivos e falsos negativos presentes na divisão da distribuição entre 0/1. Após o processamento dos dados foram retidos 6056 registros para crescimento e reprodução e 3500 quando incluído as informações de ultrassonografia.

Inicialmente, o conjunto de dados foi dividido aleatoriamente em dois subconjuntos: 80% dos dados (4844 registros – crescimento e reprodução; 2800 registros - carcaça) foram usados para treinar e testar os modelos, enquanto os 20% restantes dos dados (1514 – crescimento e reprodução; 875 - carcaça) foram excluídos da construção do modelo e retidos para uma validação externa. A seleção recursiva de recursos usando um coeficiente de variação (CV) dez vezes repetido 100 vezes com o método RF foi aplicada para selecionar automaticamente um subconjunto dos recursos mais preditivos para identificar o modelo mais parcimonioso e com melhor desempenho.

2.2.4 Aprendizagem da máquina

Para treinar e testar a relação entre o resultado (0/1 com base nos 3 critérios empíricos para descarte do animal) e características (dados de fenotípicos de crescimento, eficiência e reprodução), foi empregado um CV estratificado dez vezes repetido 10 vezes. A estratificação permitiu ter em conta as classes de produção desequilibradas e preservar a percentagem de amostras para cada classe alvo (Kohavi, 1995).

O conjunto de dados de treinamento/teste original ($n = 6056$ e $n=3500$) foi dividido aleatoriamente em 10 subconjuntos de tamanho igual. Os modelos de predição foram treinados em 9 desses subconjuntos e o último subconjunto foi usado como conjunto de teste para avaliar o desempenho dos métodos na previsão do resultado. Um total de 100 iterações foram realizadas e 10 valores médios de precisão do CV dez vezes maior foram calculados para obter a precisão final de cada método. A padronização dos dados (centro e escala) foi realizada dentro do CV.

2.2.5 Estatística adicional

2.2.5.1 Comparação de métodos de avaliação de desempenho de validação

A acurácia de cada modelo de predição no conjunto de testes foi usada como primeira métrica de comparação entre algoritmos. A acurácia de um teste representa a proporção de previsões corretas (verdadeiro positivo e verdadeiro negativo) entre todos os casos examinados. A importância do recurso foi avaliada usando o melhor modelo de previsão (aquele com maior acurácia) no conjunto de testes. As habilidades preditivas (resultado previsto 0/1, bem como a probabilidade prevista de 0 a 100% de ser classificado como 0 ou 1) de todos os modelos investigados no conjunto de validação externa foram então estimadas.

Para cada método os resultados foram analisados por meio de uma matriz de confusão e diversas estatísticas de desempenho no conjunto de validação externa, como: acurácia, sensibilidade, especificidade, valor preditivo positivo (VPP) e valor preditivo negativo (VPN). As taxas de erro falso positivo, falso negativo e total entre os métodos também foram comparadas. Foram relatados o valor Kappa de Cohen, que é uma medida do desempenho do classificador em comparação com seu desempenho simplesmente determinado pelo acaso, e a pontuação F1, que é uma média ponderada de sensibilidade e VPP.

Adicionalmente foi realizado a análise da curva característica de operação do receptor (ROC) e o valor da AUC foi utilizado para comparação de desempenho dos métodos. Além disso, como medida da qualidade da classificação, o MCC (coeficiente de correlação de Matthews) para cada método

foi calculado de acordo com a seguinte fórmula:

$$\text{MCC} = (TP * TN - FP * FN) / \sqrt{((TP + FP) * (TP + FN) * (TN + FP) * (TN + FN))}$$

Onde: TP é verdadeiro positivo, TN é verdadeiro negativo, FP é falso positivo e FN é falso negativo.

2.3 Resultados e Discussão


2.3.1 Validação cruzada k-fold aplicado nos dados de treinamento

De acordo com a validação-cruzada utilizando o método K-Fold (k = 10), a heurística representada (Figura 9), identificou-se que cinco repetições são suficientes para prosseguir com a fase de teste dos métodos de ML uma vez que a média captura de forma adequada a tendência central, baseado na linha laranja (mediana da distribuição) e o triângulo verde (média aritmética).


Durante a fase de treinamento, os métodos RN apresentou maior valor de acurácia com menor amplitude de variância. Nota-se também que valores superiores de acurácia assim como menor variação pode ser encontrada no “critério” titulado como carcaça.

Figura 9 - Distribuição dos scores de acurácia usando Análise Discriminante Linear (A), Árvores de Classificação e Regressão (B), Floresta Aleatória (C), Rede Neural (D), Naïve Bayes (E) e Máquinas de Vetores de Suporte (F) para cada número de repetições para avaliação cruzada nos dados de treinamento. *1: “critério” crescimento; 2: “critério” reprodução; 3: “critério” carcaça.


A-1




A-2




A-3




B-1




B-2




B-3




C-1




C-2




C-3




D-1




D-2




D-3




E-1




E-2




E-3




F-1



F-2



F-3





Fonte: Autor/2024

2.3.2 Comparação de métodos ML e avaliação do desempenho na previsão de animais a serem descartados baseado no conjunto de dados testes

A avaliação do desempenho de cada método ML na previsão dos animais propensos a descarte no conjunto de testes foi baseada na acurácia e nos valores kappa. Para o “critério” crescimento as acurácias variaram de 74% (DTC) a 78% (NN, RF), enquanto os valores de kappa variaram de 34% em DTC a 44% (NN, RF e NB) (Figura 10 - A); enquanto que para o “critério” reprodutivo os valores para acurácia foram próximos, variando com respectivamente em mínimos e máximos de 74% (DTC) e 76% (SVM, NB, NN e RF), enquanto que para kappa a variação foi maior, e DTC (33%) apresentou novamente valor inferior seguido de LDA (34%), ao passo que NB (40%) e RF (38%) foram superiores.

Figura 10 - Comparação do desempenho (valor de acurácia e kappa) de seis métodos de ML (Rede Neural (NN), Máquinas de Vetores de Suporte (SVM), Floresta Aleatória (RF), Árvores de Classificação e Regressão (ACR) e Naïve Bayes (NB)), executados no conjunto de testes. A: “critério” crescimento; B: “critério” reprodução; C: “critério” carcaça. *Linha vermelha representa a média entre os ML.





Fonte: Autor/2024


Por fim para o “critério” carcaça, os valores observados de acurácia foram maiores para SMV, RF e NN (86%), enquanto menor foi encontrado para NB (80%). Para kappa os maiores valores também foram encontrados para SVM (52%), NN (54%) e RF (55%). De acordo com as métricas consideradas no conjunto de teste, no agregado (“critério” crescimento + “critério” reprodução + “critério” carcaça) os métodos mais acurados foram o NN e RF.

A calibração fornece informações sobre a incerteza do modelo em prever probabilidades de dados pertencentes a cada classe a priori definida em vez de rótulos de classe brutos. Considerando que a melhor a calibração é vinculada a maior proximidade da curva a uma linha reta correspondente à função identidade


(calibração perfeita), observa-se que para o “critério” crescimento, “critério” reprodução e “critério” carcaça, o NN, RF, foram os com melhores ajustes, enquanto o NB pior.

Figura 11 - Comparação de calibração de classificadores através de curva de confiabilidade de seis métodos de aprendizado de máquina (Rede Neural (NN), Máquinas de Vetores de Suporte (SVM), Floresta Aleatória (RF), Árvores de Classificação e Regressão (ACR) e Naïve Bayes (NB)), executados no conjunto de testes. A: “critério” crescimento; B: “critério” reprodução; C: “critério” carcaça.


A



B



C



Fonte: Autor/2024

2.3.3 Comparação de métodos ML e avaliação do desempenho na previsão de animais a serem descartados baseado no conjunto de dados de validação externa

As métricas de desempenho do método no conjunto de validação externa estão resumidas na Tabela 1. Para “critério” crescimento, os métodos NN e SVM apresentaram maior acurácia (77%), ao passo que os menores foram observados para DTC (73%) e NB (74%). A sensibilidade variou de 58% (DTC) a 43% (SVM). Sensibilidade inferior a 45% foi observada apenas para LDA (44%). Alta especificidade foi observada para SVM (94%), NN (92%) e LDA (92%). A melhor precisão, ou valor preditivo positivo (VPP), foi obtida para SVM (78%), NN (74%) e LDA (73%), e o maior valor preditivo negativo (VPN) foi observado para DTC (81%), NB (81%) e RF (80%). O método RF e NN também apresentaram maiores valores de kappa (43%). Para o escore F1 o NN e SVM apresentaram maiores valores (77%). Os maiores valores do Coeficiente de Correlação de Matthew (MCC) foram observados para NN (0,45) e SVM (0,45).

Tabela 1 - Métricas de desempenho dos métodos ML (precisão (Ac) e intervalo de confiança (IC) de 95%, sensibilidade (Se), especificidade (Sp), valor preditivo positivo (VPP), valor preditivo negativo (VPN), kappa (Kp), pontuação F1 e coeficiente de correlação de Matthew (MCC)) no conjunto de validação externa para os seis métodos de aprendizado de máquina (Análise Discriminante Linear (LDA), Árvores de Classificação e Regressão (DTC), Floresta Aleatória (RF), , Rede Neural (NN), Naïve Bayes (NB), Máquinas de Vetores de Suporte (SVM)).

ML	Ac.	95%IC	Se	Sp	VPP	VPN	Kp	F1	MCC
"Critério" Crescimento									
LDA	0,76	0,73-0,80	0,44	0,92	0,73	0,78	0,40	0,76	0,42
DTC	0,73	0,71-0,78	0,58	0,81	0,60	0,81	0,39	0,73	0,39
RF	0,76	0,72-0,79	0,51	0,89	0,69	0,80	0,43	0,76	0,44
NN	0,77	0,73-0,80	0,48	0,92	0,74	0,79	0,43	0,77	0,45
NB	0,74	0,71-0,78	0,56	0,83	0,62	0,81	0,41	0,74	0,41
SVM	0,77	0,73-0,79	0,43	0,94	0,78	0,78	0,42	0,77	0,45
"Critério" Reprodução									
LDA	0,75	0,72-0,79	0,45	0,90	0,68	0,78	0,38	0,76	0,39
DTC	0,75	0,71-0,79	0,63	0,80	0,61	0,83	0,43	0,76	0,43
RF	0,76	0,73-0,78	0,56	0,87	0,67	0,81	0,44	0,78	0,45
NN	0,78	0,74-0,80	0,52	0,90	0,73	0,81	0,46	0,79	0,47
NB	0,73	0,70-0,79	0,55	0,83	0,60	0,80	0,39	0,75	0,39
SVM	0,78	0,73-0,81	0,45	0,94	0,80	0,79	0,45	0,79	0,48
"Critério" carcaça									
LDA	0,80	0,75-0,82	0,44	0,91	0,60	0,84	0,39	0,80	0,40
DTC	0,84	0,77-0,89	0,40	0,98	0,84	0,84	0,45	0,84	0,40
RF	0,81	0,77-0,89	0,55	0,89	0,59	0,87	0,45	0,81	0,45
NN	0,81	0,76-0,89	0,53	0,89	0,60	0,86	0,44	0,81	0,44
NB	0,75	0,71-0,84	0,51	0,82	0,47	0,85	0,32	0,75	0,32
SVM	0,83	0,77-0,88	0,51	0,93	0,69	0,86	0,48	0,83	0,49

Para "critério" reprodução, os métodos NN e SVM apresentaram maior acurácia (77%), ao passo que o menor foi novamente o NB (73%). A sensibilidade foi maior em DTC (63%) e RF (56%), e menores para LDA (45%) e SVM (45%). Alta especificidade corroborou com o observado para "critério" crescimento, sendo maiores valores encontrados para SVM (94%), NN (90%) e LDA (90%). Com relação ao VPP e VPN, valores superiores foram observados para SVM (78%) e DTC (81%) respectivamente. Novamente para o valor de kappa o NN (46%) foi superior. O NN (79%, 0.47) e SVM (79%, 0.48) foram superiores para F1 e MCC.

Por fim, para o "critério" carcaça, em geral, os modelos apresentaram valores superiores para os dois primeiros "critérios". Os métodos DTC (84%) e SVM (83%) apresentaram maior acurácia. A sensibilidade variou de 55% (RF) a 40% (DTC), enquanto a especificidade variou de 98% (DTC) a 82% (NB). Valores inferiores para VPP e VPN foi observado para RF (59%) e NB (47%), e LDA (84%) e DTC (84%) respectivamente. Valores de kappa foram superiores para DTC (45%) e RF (45%), ao passo que menores para LDA (39%) e NB (32%). Para o escore F1 o DTC (83%) e SVM (84%) apresentaram maiores valores. Os maiores valores do Coeficiente de Correlação de Matthew (MCC) foi para SVM

(0,49).

O desempenho semelhante dos métodos investigados nos conjuntos de teste e validação indicou a ausência de overfitting (Ying, 2018). Estes resultados sugeriram a possibilidade de aplicar os resultados deste estudo. O desempenho dos métodos de ML em conjuntos de teste e validação foi avaliado por meio de diferentes métricas, como acurácia, taxas de verdadeiros e falsos positivos, precisão, pontuação F e valor de AUC. Embora tenha se tornado uma prática comum fornecer diversas métricas de avaliação, diferentes medidas pressupõem um caso de uso diferente.

A sensibilidade baixa a moderada (40-66%) e a especificidade relativamente alta (> 80%) de todos os métodos de ML avaliados no presente estudo para todos os “critérios” sugeriram seu alto poder para identificar corretamente animais passíveis de serem mantidos no rebanho (ainda um resultado valioso para estreitar o grupo de animais que poderiam ser descartados).

A acurácia, que representa o número de previsões corretas feitas pelo modelo sobre o número total de previsões, é uma das métricas mais utilizadas, porém não é suficiente por si só para avaliar o desempenho do modelo. Na verdade, dependendo do caso específico, o custo do falso positivo e do falso negativo pode não ser o mesmo. Assim, a avaliação do modelo deve basear-se também em outras métricas, por ex. recall ou sensibilidade (se quisermos minimizar falsos negativos) e precisão ou PPV (se quisermos minimizar falsos positivos). Para obter o modelo com melhor desempenho otimizando a proporção de falsos positivos e falsos negativos, o escore F1 deve ser considerado, pois representa a média harmônica tanto da precisão quanto do recall.

Os erros de classificação (falso positivo, falso negativo e total), com base na precisão do método, são mostrados na Figura 6. Para o “critério” crescimento o erro falso negativo foi maior para LDA (33%) e SVM (33%) do que outros métodos, enquanto o erro mais baixo foi relatado para RF (29%) e NB (29%). O maior erro falso positivo foi estimado para NB (56%) e DTC (56%), e o menor para SVM (32%) e NN (35%). Considerando o erro total, os piores desempenhos foram reportados para NB (36%) e DTC (36%), enquanto o menor erro foi observado para NN (31%) e RF (32%). Para o “critério” reprodução o erro falso negativo foi maior para DTC (33%), enquanto o erro mais baixo foi relatado para

RF (25%). O maior erro falso positivo foi estimado para NB (67%) e RF (51%), e o menor para SVM (31%).

Considerando o erro total, os piores desempenhos foram reportados para NB (36%) e DTC (35%), enquanto o menor erro foi observado para NN (29%) e SVM (28%). Por fim, para o “critério” carcaça o erro falso negativo foi maior para DTC (22%), enquanto o erro mais baixo foi relatado para NB (15%). O maior erro falso positivo foi estimado para NB (81%) e RF (37%), e o menor para DTC (16%). Considerando o erro total, o pior desempenho foi reportado para NB (27%), enquanto o menor erro foi observado para NN (19%).

Reduzir os falsos negativos (isto é, classificar erroneamente as vacas como saudáveis no DT subsequente) e equilibrar também os falsos positivos representaria a melhor abordagem para o nosso caso específico. Assim, NN, RF parecem ser os melhores métodos para prever animais propensos a descarte. No entanto, embora alguns métodos tenham tido melhor desempenho que outros, as precisões de previsão de todos os métodos foram superiores a 70%, o que significa que em um rebanho com 100 bovinos podemos prever corretamente pelo menos 70 animais.

Para todos os “critérios” o NN (AUC: 79%, 79 e 86%) e RF (AUC: 78%, 78 e 86%) apresentou a maior área sob a curva; esses métodos tiveram as melhores curvas de característica de operação do receptor (ROC) (Figura 7). Tanto para o “critério” crescimento (70%), como para reprodução (72%), o menor do valor de AUC mais baixa foi relatada para DTC. Já para o “critério” carcaça, os menores valores foram observados para NB (81%) e SVM (81%). A AUC é métrica amplamente utilizada para avaliação de problemas de classificação e tem a grande vantagem de ser independente da taxa de resultados, assim como do MCC. O método DTC apresentou um desempenho relativamente fraco com base no valor da AUC.


De acordo com várias destas métricas, NN, RF foram os métodos com melhor desempenho na previsão, tanto no conjunto de testes como no conjunto de validação. Em detalhes, os métodos que obtiveram a menor porcentagem de erro total para previsões no conjunto de validação, foram o NN e RF tendo entre os menores erros falsos negativos e os métodos lineares entre os menores erros falsos positivos.

O método de RF é baseado na classificação por árvore de decisão e


desenvolve um grupo de modelos de classificação estruturados em árvore. Cada árvore contribui com uma opinião sobre como os dados devem ser classificados (Shahinfar et al., 2014). Já o método NN são construídas predominantemente usando unidades de computação idealizadas com valores de ativação contínua e um conjunto de entradas ponderadas.

Estas unidades são comumente chamadas de “neurônios” e usam funções de ativação não lineares diferenciáveis. As funções de ativação não linear tornam representativamente significativo empilhar mais de uma camada e a existência de suas derivadas torna possível o uso de métodos de otimização baseados em gradiente para treinamento (Tavanaei et al., 2019).


Figura 12 - Comparação do desempenho (erro falso negativo (diagonal inferior esquerda), erro falso positivo (diagonal superior direita) no conjunto de validação externa para os seis métodos de aprendizado de máquina (Análise Discriminante Linear (A), Árvores de Classificação e Regressão (B), Floresta Aleatória (C), Rede Neural (D), Naïve Bayes (E) e Máquinas de Vetores de Suporte (F)) *1: “critério” crescimento; 2: “critério” reprodução; 3: “critério” carcaça.




C-1




C-2




C-3




D-1




D-2




D-3




E-1




E-2




E-3




F-1



F-2




F-3




Fonte: Autor/2024


Figura 13 - Comparando curvas ROC de seis métodos de ML (Análise Discriminante Linear (A), Árvores de Classificação e Regressão (B), Floresta Aleatória (C), Rede Neural (D), Naïve Bayes (E) e Máquinas de Vetores de Suporte (F)). Em cada parcela, foram relatados a área sob a curva (AUC) e o intervalo de confiança de 95%. *1: “critério” crescimento; 2: “critério” reprodução; 3: “critério” carcaça.




C-1




C-2




C-3




D-1




D-2




D-3




E-1




E-2




E-3




F-1



F-2



F-3



Fonte: Autor/2024

Em geral, importante destacar que a transformação da agricultura evoluiu vários aspectos da gestão para sistemas de ML, com o objetivo de rentabilizar os dados cada vez maiores provenientes de inúmeras fontes (Benos et al., 2021). Todavia, apesar do grande número de estudos publicados sobre métodos de ML aplicados à ciência animal, ainda não ocorreu uma implementação prática confiável da maioria dos algoritmos testados para decisão de manejo (Bobbo et al., 2021).

Isto pode dever-se à disponibilidade de dados de formação deficientes. Além disso, tem sido apontada a necessidade de algoritmos de ML mais eficientes e arquiteturas computacionais escaláveis, o que pode levar ao processamento rápido de informações (Wäldchen et al., 2018, Ang et al., 2021).

Para melhorar a precisão das previsões, devem ser considerados os dados obtidos de muitos rebanhos diferentes e registados durante períodos de tempo mais longos, e devem ser criados grandes conjuntos de dados integrados de alta qualidade. Outra possibilidade seria o desenvolvimento de algoritmos mais específicos para os rebanhos, centrados nas necessidades específicas de cada agricultor (Bobbo et al., 2021).

2.4 Conclusão

Nossos resultados sublinharam a dificuldade em definir os melhores métodos a serem utilizados na análise de ML, pois alguns métodos podem ser afetados pela estrutura e distribuição dos dados. No entanto, os resultados deste estudo representam um prelúdio valioso para o desenvolvimento de modelos de ML que fornecerão aos pecuaristas uma previsão de animais a serem descartados ou remanejado a um tipo de tratamento específico, utilizando informações já disponíveis.

2.5 Referências Bibliográficas

Associação Brasileira das Indústrias Exportadoras de Carne (ABIEC). **Beef Report Perfil da Pecuária no Brasil**. 2022. Disponível em: <http://abiec.com.br/publicacoes/beef-report-2022/>. Acesso em: 10 ago. 2023.

ADAM, G.; RAMPASEK L.; SAFIKHANI, Z.; SMIRNOV, P.; HAIBE-KAINS, B.; GOLDENBERG, A. Machine learning approaches to drug response prediction:

challenges and recent progress. **Nature partner journals Precision oncology**, Austin, v.4, n.19, p.4-19, 2020. Doi: <https://doi.org/10.1038/s41698-020-0122-1>.

ADESOGAN, A. T.; HAVELAAR, A. H.; MCKUNE, S. L.; EILITTA, M.; DAHL, G. E. Animal source foods: Sustainability problem or malnutrition and sustainability solution? Perspective matters. **Global Food Security**, Belfast, v. 25, p. 100371, 2020. Doi: <https://doi.org/10.1016/j.gfs.2020.100371>.

ALAM, Mahboob; CHO, Kwang-Hyun; LEE, Seung-Soo; CHOY, Yun-Ho; KIM, Hyeong-Sun; CHO, Chang-Il; CHOI, Tae-Jeong. Effect of carcass traits on carcass prices of holstein steers in Korea. **Asian-Australasian Journal of Animal Sciences**, Seul, v. 26, p. 1388-1398, 2013.

ALONSO, J.; VILLA, A.; BAHAMONDE, A. Improved estimation of bovine weight trajectories using Support Vector Machine Classification. **Computers and Electronics in Agriculture**, Amsterdam, v. 110, p. 36–41, 2015. Doi: <https://doi.org/10.1016/j.compag.2014.10.010>.

ALONSO, J.; CASTAÑÓN, Á. R.; BAHAMONDE, A. Support Vector Regression to predict carcass weight in beef cattle in advance of the slaughter. **Computers and Electronics in Agriculture**, Amsterdam, v. 91, p. 116–120, 2013. Doi: <https://doi.org/10.1016/j.compag.2012.12.009>.

Associação Nacional de Criadores e Pesquisadores. Características avaliadas (ANCP). **Características avaliadas**. 2023. Disponível em: <https://www.ancp.org.br/programas/conceitosbasicos/caracteristicas-avaliadas/>. Acesso em: 10 ago. 2023.

ANG, Kenneth L. M.; SENG, Jasmine K. P. Big Data and Machine Learning with Hyperspectral Information in Agriculture. **Institute of Electrical and Electronics Engineers Access**, Piscataway, v. 9, p. 36699–36718, 2021.

ARCHER, J.A.; BARWICK, S.A.; GRASER, H.U. Economic evaluation of beef cattle breeding schemes incorporating performance testing of young bulls for feed intake. **Australian Journal of Experimental Agriculture**, Melbourne, v. 44, n. 5, p. 393–404, 2004. Doi: <https://doi.org/10.1071/EA02054>.

BASARAB, J. A.; COLAZO, M. G.; AMBROSE, D. J.; NOVAK, S.; MCCARTNEY, D.; BARON, V. S. Residual feed intake adjusted for backfat thickness and feeding frequency is independent of fertility in beef heifers. **Canadian Journal of Animal Science**, Ottawa, v. 91, n. 4, p. 573–584, 2011. Doi: <https://doi.org/10.4141/CJAS2011-011>.

BENOS, Lefteris; TAGARAKIS, Aristotelis C.; DOLIAS, George; BERRUTO, Remigio; KATERIS, Dimitrios; BOCHTIS, Dionysis. Machine Learning in Agriculture: A Comprehensive Updated Review. **Sensors**, Basileia, v. 21, n. 11, p. 3758, 2021.

BERRY, D. P.; WALL, E.; PRYCE, J. E. Genetics and genomics of reproductive performance in dairy and beef cattle. **Animal**, Cambridge, v. 8, n. s1, p. 105–121,

2014. Doi: <https://doi.org/10.1017/S175173111400030X>.

BOBBO, T.; BIFFANI, S.; TACCIOLI, C.; PENASA, M.; CASSANDRO, M. Comparison of machine learning methods to predict udder health status based on somatic cell counts in dairy cows. **Scientific Reports**, Londres, v. 11, n. 1, p. 13642, 2021.

BREIMAN, L.; FRIEDMAN, J.; OLSHEN, R.; STONE, C. **Classification and Regression Trees**. Belmont, CA: Wadsworth International Group, 1984. 358 p.

BOHANEC, M.; KLJAJIČ BORŠTNAR, M.; ROBNIK-ŠIKONJA, M. Explaining machine learning models in sales predictions. **Expert Systems with Applications**, Oxford, v. 71, p. 416–428, 2017. Doi: <https://doi.org/10.1016/j.eswa.2016.11.010>.

COCKBURN, M. Application and prospective discussion of machine learning for the management of dairy farms. **Animals**, Basileia, v. 10, n. 9, p. 1690, 2020. Doi: <https://doi.org/10.3390/ani10091690>.

COMINOTTE, A.; FERNANDES, A. F. A.; DOREA, J. R. R.; ROSA, G. J. M.; LADEIRA, M. M.; VAN CLEEF, E. H. C. B.; PEREIRA, G. L.; BALDASSINI, W. A.; MACHADO NETO, O. R. Automated computer vision system to predict body weight and average daily gain in beef cattle during growing and finishing phases. **Livestock Science**, Amsterdam, v. 232, p. 103904, 2020. Doi: <https://doi.org/10.1016/j.livsci.2019.103904>.

COUTINHO, C. C.; MERCADANTE, M. E. Z.; JORGE, A. M.; PAZ, C. C. P.; EL FARO, L.; MONTEIRO, F. M. Growth curves of carcass traits obtained by ultrasonography in three lines of Nellore cattle selected for body weight. **Genetics and Molecular Research**, Ribeirão Preto, v. 14, p. 14076-14087, 2015. Disponível: https://www.researchgate.net/publication/283500066_Growth_curves_of_carcass_traits_obtained_by_ultrasonography_in_three_lines_of_Nellore_cattle_selected_for_body_weight. Acessado 10 de Agosto de 2023.

DELGADO, C.; ROSEGRANT, M.; STEINFELD, H.; EHUI, S.; COURBUIIS, C. Livestock to 2020: the next food revolution. **Outlook on Agriculture**, London, v. 30, n. 1, p. 27–29, 2001. Doi: <https://doi.org/10.5367/000000001101292321>.

DE VRIES, M.; DE BOER, I. J. M. Comparing environmental impacts for livestock products: a review of life cycle assessments. **Livestock Science**, Amsterdã, v. 128, p. 1–11, 2010. Doi: <https://doi.org/10.1016/j.livsci.2009.11.007>

DICK, M.; SILVA, M. A.; SILVA, R. R. F.; FERREIRA, O. G. L.; MAIA, M. S.; LIMA, S. F.; PAIVA NETO, V. B.; DEWES, H. Environmental impacts of Brazilian beef cattle production in the Amazon, Cerrado, Pampa, and Pantanal biomes. **Journal of Cleaner Production**, Amsterdam, v. 311, p. 127750, 2021. Doi: <https://doi.org/10.1016/j.jclepro.2021.127750>.

DIEZ, J.; ALBERTI, P.; RIPOLL, G.; LAHOZ, F.; FERNÁNDEZ, I.; OLLETA, J. L.;

PANEA, B.; SAÑUDO, C.; BAHAMONDE, A.; GOYACHE, F. Using machine learning procedures to ascertain the influence of beef carcass profiles on carcass conformation scores. **Meat Science**, Oxford, v. 73, p. 109-115, 2006. Doi: <https://doi.org/10.1016/j.meatsci.2005.11.004>.

DING, M. Q.; CHEN, L.; COOPER, G. F.; YOUNG, J. D.; LU, X. Precision oncology beyond targeted therapy: combining omics data with machine learning matches the majority of cancer cells to effective therapeutics. **Molecular Cancer Research**, Philadelphia, v. 16, n. 2, p. 269–278, 2018. Disponível em: <https://doi.org/10.1158/1541-7786.MCR-17-0358>.

DISKIN, M. G.; KENNY, D. A. Managing the reproductive performance of beef cows. **Theriogenology**, New York, v. 86, n. 1, p. 379-387, 2016. Doi: <https://doi.org/10.1016/j.theriogenology.2016.04.052>.

FANG, K.; SHEN, C.; KIFER, D.; YANG, X. Prolongation of SMAP to Spatiotemporally Seamless Coverage of Continental U.S. Using a Deep Learning Neural Network. **Geophysical Research Letters**, Washington, DC, v. 44, n. 21, p. 11030–11039, 2017. Doi: <https://doi.org/10.1002/2017GL075619>.

FEI, Y.; GAO, K.; HU, J.; TU, J.; LI, W.; WANG, W.; ZONG, G. Predicting the incidence of portosplenomesenteric vein thrombosis in patients with acute pancreatitis using classification and regression tree algorithm. **Journal of Critical Care**, New York, v. 39, p. 124-130, 2017. Doi: <https://doi.org/10.1016/j.jcrc.2017.02.016>.

FERRAZ, J. B. S.; FELICIO, P. E. Production systems – An example from Brazil. **Meat Science**, Oxford, v. 84, n. 2, p. 238-243, 2010. Doi: <https://doi.org/10.1016/j.meatsci.2009.06.009>.

FRIGO, E.; DECHOW, C. D.; PEDRON, O.; CASSELL, B. G. The genetic relationship of body weight and early-lactation health disorders in two experimental herds. **Journal of Dairy Science**, Champaign, v. 93, n. 3, p. 1184-1192, 2010. Doi: <https://doi.org/10.3168/jds.2009-2313>.

GHAFOURI-KESBI, F.; ABBASI, M. A.; AFRAZ, F.; BABAEI, M.; BANEH, H.; ARPANAHI, R. A. Genetic analysis of growth rate and Kleiber ratio in Zandi sheep. **Tropical Animal Health and Production**, Edinburgh, v. 43, n. 6, p. 1153-1159, 2011. Doi: <https://doi.org/10.1007/s11250-011-9816-1>.

HAKEM, M.; BOULOUARD, Z.; KISSI, M. Classification of Body Weight in Beef Cattle via Machine Learning Methods: A Review. **Procedia Computer Science**, Amsterdã, v. 198, p. 263–268, 2022. Doi: <https://doi.org/10.1016/j.procs.2021.12.238>.

LIAKOS, K. G.; BUSATO, P.; MOSHOU, D.; PEARSON, S.; BOCHTIS, D. Machine Learning in Agriculture: A Review. **Sensors**, Basileia, v. 18, n. 8, p. 2674, 2018. Doi: <https://doi.org/10.3390/s18082674>.

MALHADO, C. H. M.; MALHADO, A. C. M.; MARTINS FILHO, R.; CARNEIRO,

P. L. S.; PALA, A.; CARRILLO, J. A. Age at first calving of Nellore cattle in the semi-arid region of northeastern Brazil using linear, threshold, censored and penalty models. **Livestock Science**, Amsterdã, v. 154, n. 1-3, p. 28–33, 2013. Doi: <https://doi.org/10.1016/j.livsci.2013.02.020>.

MILLER, G. A.; HYSLOP, J. J.; BARCLAY, D.; EDWARDS, A.; THOMSON, W.; DUTHIE, C. A. Using 3D Imaging and Machine Learning to Predict Liveweight and Carcass Characteristics of Live finishing Beef Cattle. **Frontiers in Sustainable Food Systems**, Lausanne, v. 3, p. 30, 2019. Doi: <https://doi.org/10.3389/fsufs.2019.00030>.

NUCCI, H. H. P.; ISHII, R. P.; COSTA GOMES, R.; COSTA, C. S.; FEIJÓ, G. L. D. **Classification of Carcass Fatness Degree in Finishing Cattle Using Machine Learning**. p. 519–535. 2020. In: GERVASI, O.; MURGANTE, B.; MISRA, S.; GARAU, C.; BLECIC, I.; IANIAR, D.; APDUHAN, B. O.; ROCHA, A. M. A. C.; TARATINO, E.; TORRE, C. M.; KARACA, Y. Computational Science and Its Applications – ICCSA 2020. Cham: Springer. Doi: https://doi.org/10.1007/978-3-030-58814-4_38.

REZENDE, M. P. G.; MALHADO, C. H. M.; BIFFANI, S.; CARNEIRO, P. L. S.; BOZZI, R. Genetic diversity derived from pedigree information and estimation of genetic parameters for reproductive traits of Limousine and Charolais cattle raised in Italy. **Italian Journal of Animal Science**, Bologna, v. 19, n. 1, p. 762–771, 2020. Doi: <https://doi.org/10.1080/1828051X.2020.1794354>.

ROMERO, M. P.; CHANG, Y. M.; BRUNTON, L. A.; PARRY, J.; PROSSER, A.; UPTON, P.; REES, E.; TEARNE, O.; ARNOLD, M.; STEVENS, K.; DREWE, J. A. Decision tree machine learning applied to bovine tuberculosis risk factors to aid disease control decision making. **Preventive Veterinary Medicine**, Amsterdam, v. 175, p. 104860, 2020. Doi: <https://doi.org/10.1016/j.prevetmed.2019.104860>.

SHAHINFAR, S.; AL-MAMUN, H. A.; PARK, B.; KIM, S.; GONDRO, C. Prediction of marbling score and carcass traits in Korean Hanwoo beef cattle using machine learning methods and synthetic minority oversampling technique. **Meat Science**, Oxford, v. 161, p. 107997, 2020.

TAVANAEI, A.; GHODRATI, M.; KHERADPISHEH, S. R.; MASQUELIER, T.; MAIDA, A. Deep learning in spiking neural networks. **Neural Networks**, Oxford, v. 111, p. 47–63, 2019. Doi: <https://doi.org/10.1016/j.neunet.2018.12.002>.

WANG, Y.; ZHAO, Y.; THERNEAU, T. M.; ATKINSON, E. J.; TAFTI, A. P.; ZHANG, N.; AMIN, S.; LIMPER, A. H.; KHOSLA, S.; LIU, H. Unsupervised machine learning for the discovery of latent disease clusters and patient subgroups using electronic health records. **Journal of Biomedical Informatics**, Amsterdam, v. 102, p. 103364, 2020. Doi: <https://doi.org/10.1016/j.jbi.2019.103364>.

XIONG, Y.; CONDOTTA, I. C. F. S.; MUSGRAVE, J. A.; BROWN-BRANDL, T. M.; MULLINIKS, J. T. Estimating body weight and body condition score of mature

beef cows using depth images. **Translational Animal Science**, Cary, v. 7, n. 1, p. txad085, 2023. Doi: <https://doi.org/10.1093/tas/txad085>.

CAPÍTULO 3 – APRENDIZAGEM DE MÁQUINA APLICADA A INDICADORES FENOTÍPICOS PARA AGRUPAMENTO DE BOVINOS DE CORTE DE ACORDO COM SEU DESEMPENHO

Análise preditiva para decisões estratégicas na bovinocultura de corte

Resumo

A bovinocultura de corte em modelo convencional divide-se em cria, recria, e por fim duas direções, a reposição ou terminação. Durante essas fases, animais podem ser descartados ou direcionados a um manejo apropriado para a sua destinação final. Essa decisão comumente baseia-se na interação entre custo de manutenção do animal com seu desempenho no crescimento, capacidade reprodutiva e modelagem corporal como indicativo do rendimento de sua carcaça. Assim, objetivamos através de análise preditiva de dados, classificar grupos de bovinos de acordo com desempenho fenotípico (crescimento, reprodutiva, índice de Kleiber (IK), ultrassonografia e indicadores econômicos) em animais 10% inferiores, grupo intermediário e animais 10% superiores aplicando árvore de classificação e regressão, bem como, análise multivariada. A correlação preditiva quadrada para todos os indicadores foi superior a 90%. A raiz do erro quadrático médio da previsão foi satisfatória. Foi possível discriminar os grupos de animais superiores e inferiores através dos dados preditivos x dados reais. Assim conclui-se que a metodologia empregada tem potencial para discriminar antecipadamente grupos de animais baseado no seu desempenho para diversos indicadores.

Palavras-chave: Bovinocultura. Gestão Rural. Indicadores. Inteligência artificial. Previsão fenotípica.

3.1 Introdução

A carne como fonte de proteína animal é considerada essencial para um adequado crescimento e desenvolvimento humano (Higgs, 2000), além de ter sido importante na evolução da espécie humana, principalmente no desenvolvimento cerebral e intelectual (Pereira e Vicente, 2013). Entre as principais espécies usadas na pecuária, cita-se a bovina, desde carne até produtos lácteos.

Elaborar novas tecnologias para aumentar a produtividade e rentabilidade dessa atividade é prioridade para atender à crescente necessidade desse tipo de alimento. Uma das alternativas para alcançar esse objetivo, é o manejo operacional a nível de fazenda, advindo de estratégias tomadas pelo pecuarista com base em informações da produtividade do seu rebanho e tendências do mercado.

Nesse sentido, a criação de ferramentas de previsões pode auxiliar na identificação antecipada da melhor estratégia a ser adotada permitindo uma maior rentabilidade econômica dentro desse ciclo. Modelos estatísticos tradicionais e abordagens de aprendizado de máquina mais sofisticadas têm sido usadas para criar preditores de resposta em setores como por exemplo na saúde (Adam et al., 2020, Ding et al., 2018), pecuária (Romero et al., 2020) e economia (Athey e Imbens, 2019).

Neste estudo, objetivamos através de análise preditiva de dados, classificar grupos de bovinos de acordo com desempenho fenotípico (crescimento, reprodutivo, índice de Kleiber (IK), ultrassonografia e indicadores econômicos) em animais 10% inferiores, grupo intermediário e animais 10% superiores aplicando árvore de classificação e regressão, bem como, análise multivariada.

3.2 Material e métodos

3.2.1 Dados

Para simulação das análises preditivas, utilizou-se um banco de dados inicial com 18716 bovinos puro de origem da raça Nelore coletado via Associação Nacional de Criadores e Pesquisadores (ANCP, 2023).

Foram utilizadas informações fenotípicas de crescimento (pesos, ganhos médios diários de pesos e índice de Kleiber para as idades ajustadas aos 120, 210, 365 e 450 dias), reprodutiva (perímetro escrotal aos 365 e 450 dias), ultrassonografia (área de olho de lombo, marmoreiro, espessura de gordura subcutânea e espessura de gordura subcutânea na garupa) e índice monentum de ganho de peso e peso ajustados aos 210, 365 e 450 dias (Tabela 2).

Tabela 2 - Análise descritiva das características fenotípicas e indicador

Características	Quantidade	Media	Desvio padrao
	Crescimento		
Peso aos 120 dias	18716	138.77	22.25
Peso aos 210 dias	17207	203.65	32.81
Peso aos 365 dias	13297	277.15	45.84
Peso aos 450 dias	13391	320.19	53.85
Ganho medio diario entre 120 e 210 dias	16905	0.715	0.199
Ganho medio diario entre 210 e 365 dias	12311	0.468	0.180
Ganho medio diario entre 365 e 450 dias	11708	0.514	0.257
Indice de Kleiber aos 210 dias	16905	1.31	0.27
Indice de Kleiber aos 365 dias	12311	0.678	0.215
Indice de Kleiber aos 450 dias	11708	0.66	0.29

	Reprodutiva		
Perimetro escrotal aos 365 dias	9159	22.56	2.55
Perimetro escrotal aos 450 dias	10779	25.88	3.15
	Ultrasonografia		
Area de olho de lombo	4312	60.39	12.62
Espessura de gordura subcutânea	4308	2.49	0.92
Espessura de gordura subcutânea na garupa	4310	3.43	1.51
Marmoreio	397	2.13	0.73
	Indice de precificação		
Estimado com peso aos 210 dias	16905	2343.60	377.67
Estimado com peso aos 365 dias	12311	3190.37	532.53
Estimado com peso aos 450 dias	11708	3695.09	631.39
Estimado com ganho de peso entre 120 e 210 dias	16905	8.23	2.29
Estimado com ganho de peso entre 210 e 365 dias	12311	5.39	2.07
Estimado com ganho de peso entre 365 e 450 dias	11708	5.92	2.96
	Indice monentum		
Estimado com precificação aos 210 dias	16905	47.36	16.02
Estimado com precificação aos 365 dias	12311	46.15	26.64
Estimado com precificação aos 450 dias	11708	45.31	15.56
Estimado com precificação entre 120 e 210 dias	16905	46.64	26.52
Estimado com precificação entre 210 e 365 dias	12311	47.27	15.53
Estimado com precificação entre 365 e 410 dias	11708	47.54	25.80

Fonte: autor/2023.

Os valores de peso corporal foram ajustados aos 120, 210, 365 e 450 dias de idade de acordo com as seguintes referências (Lôbo, 1992;). Equação 1, utilizando o peso mais próximo da idade de ajuste for o primeiro peso, e o inverso para equação 2.

Equação 1

$$APEi = \text{Peso } b + GMD \times d \times i - b$$

Equação 2

$$APEi = \text{Peso } a + GMD \times d \times i - a$$

Onde ABW foi o peso ajustado no tempo i (i=60, 210 e 365 dias); Peso foi o peso registrado antes (b) ou após (a) tempo i; GMD foi o ganho médio diário estimado entre o tempo a e o tempo b; e d a distância entre o tempo i e o tempo b ou entre o tempo a e o tempo i. A fórmula usada para estimar a proporção de

Kleiber em idades padrão foi de acordo com a equação de Kleiber, (1936).

$$IK_i = \frac{GMD_j}{Peso_i^{0,75}}$$

Onde: IK_i é o índice de Kleiber na idade i , o GMD foi o ganho médio diário estimado entre o tempo a e o tempo b e $Peso_i^{0,75}$ é o peso metabólico. Para índice monentum foi feito uma adequação do modelo de Willians utilizando as equações abaixo:

$$IGM = \text{indivíduo } i = \text{Peso}_2 - \text{Peso}_1 \times \text{Cotação}$$

$$IM = \text{indivíduo } i = \text{Peso} \times \text{Cotação}$$

Onde: peso 1 é o peso inicial, peso 2 é o peso final, n é a diferença em dias entre os pesos e cotação é o preço do fechamento do ativo em Kg/R\$, ou seja, a precificação do animal. Em seguida, calculou-se o método Quartil considerando uma distribuição gaussiana para agrupar indivíduos com valores máximo e mínimo para ambos os indicativos.

Utilizando o IGM e o IM individual, e a média do grupo máximo e mínimo, transformou-se em um índice no qual compara-se os animais de forma contemporânea, aplicando a seguinte equação:

$$\text{Índice} = \frac{\text{máximo } n\text{-indivíduo } i}{\text{mínimo } n\text{-indivíduo } i} \times 100$$


Onde: máximo n é a média do grupo com valores do quartil superior (IGM, IM), indivíduo i é o valor fenotípico do indivíduo (IGM, IM), mínimo n é a média do grupo com valores do quartil inferior (IGM, IM).

3.2.2 Análise estatística


Para verificar o risco de ser descartado ou não entre as fases bem como a indicação a reposição ou a terminação, utilizou-se a seguinte estratégia representada na Figura 14, no qual é proposto utilizar características coletadas em cada fase para predizer a fase futura e posteriormente uma definição dos grupos de animais em 10% superiores ou inferiores. Para aprendizagem de máquina de árvore de decisão, foram utilizados algoritmos implementados em Python 3.8.10.

Figura 14 - Ilustração da aplicação da metodologia de análise para predição dos dados (A) e com indicações das fases (B).

A



B



Fonte: Autor/2023.


Foram utilizados como efeitos no modelo, ano estação de nascimento, idade em classe da vaca ao parto, idade em classe da análise de ultrassonografia. Para edição dos dados foram utilizados os pacotes Numpy, Pandas, Datetime, Matplotlib. Para o desenvolvimento da aplicação de machine learning foi utilizado o *Sklearn* (*sklearn. tree*, *sklearn. ensemble*, *sklearn*.

preprocessing, *sklearn.model_selection*, *sklearn.linear_model*) com *DecisionTreeRegressor*. Para verificar a previsão dos dados previstos foi avaliado a correlação quadrada (r^2) entre os valores preditos e observados foi utilizada para avaliar a precisão das equações desenvolvidas (Tedeschi, 2006). Além da raiz do erro quadrático médio da predição.

Posteriormente, foi criado para cada análise preditiva, um gráfico de probabilidade normal utilizando seaborn e statsmodels, *graphics.gofplots* por meio do método q-q (Quantil-to-Quantile) para verificar se o conjunto de dados estimados pela predição é normalmente distribuído ou não contra uma distribuição normal teórica.

Utilizando os dados oriundos da análise preditiva, para cada fase, criou-se 3 grupos (Figura 15), sendo titulados como superior 10%, intermediário e inferior 10%, no qual o primeiro baseia-se na concentração dos animais identificados no percentil de 10% melhores para a característica, o inverso corresponde ao último grupo, enquanto o central são os demais 80% dos animais.

Figura 15 - Fluxo demonstrativo da criação dos grupos.



Fonte: Autor/2023.

Após a criação dos grupos, tornou-se aos dados reais para todas as demais análises. Inicialmente, os grupos foram comparados utilizando análise multivariada por meio de componentes principais (*sklearn.decomposition* – PCA). Para determinar a quantidade de componentes a serem mantidos para interpretação dos resultados, utilizou-se o critério de variância, ou seja, o ponto de inflexão no gráfico de curva de autovalores.

Foi construído um gráfico biplot incluindo árvore geradora mínima (minimum spanning tree, onde cada linha como um ponto G_n com coordenadas (g_{i1}, g_{i2}) , $i = 1, \dots, n$, e cada coluna um vetor começa na origem até o ponto H_m com uma coordenada (h_{j1}, h_{j2}) , $j = 1, \dots, p$, em um gráfico bidimensional, ou seja, os vetores representam as variáveis e os pontos representam os grupos (superior 10%, intermediário e inferior 10%).

3.3 Resultados e Discussão


A correlação preditiva quadrada para todos os indicadores foi maior de 90%, enquanto a raiz do erro quadrático médio da previsão foi de 3,24, 5,42, 1,56, 0,06, 2,67, 5,03, 1,42, 0,57, 3,06, 0,90 e 1,13 para IM365, IGM365, PE365, IK365, IM450, IGM450, PE450 e IK450, AOL, EG, EGP8 e MAR (Figura 3).







Ambas as análises utilizadas na validação para verificar os resultados da previsão, estão entre os principais indicadores para demonstrar o desempenho para um modelo de previsão, uma vez que medem diferenças entre valores previstos e os valores reais (Hallak e Pereira Filho, 2011).

Para o erro quadrático médio, quanto menor é o valor melhor é o modelo de previsão, nesse sentido, verifica-se que para os índices de Kleiber em ambas as idades, a previsão foi a mais acurada, ao passo que para índice momentum de ganho de peso o inverso foi observado.

Para IGM450, EG e EGP8 os valores estimados pela previsão não apresentaram uma normalidade satisfatória, indicando dados assimétricos a esquerda (Figura 4). Já para as demais, observou-se que alguns valores dos resíduos apresentavam pequenos desvios em relação a reta teórica.


Figura 16 - Precisão dos dados reais com o predito. A: Índice de Kleiber aos 365 dias; B: Perímetro escrotal aos 365 dias; C: Índice momentum de peso aos 365 dias; D: Índice momentum de ganho de peso aos 365 dias; E: Índice de Kleiber aos 450 dias; F: Perímetro escrotal aos 450 dias; G: Índice momentum de peso aos 450 dias; H: Índice momentum de ganho de peso aos 450 dias; I: Area de olho de lombo; J: Espessura de gordura subcutânea; K: Espessura de gordura subcutânea na garupa; L: Marmoreio.






Fonte: Autor/2023.

Figura 17 - Verifica de probabilidade normalidade para os dados preditivos. A: Índice de Kleiber aos 365 dias; B: Perímetro escrotal aos 365 dias; C: Índice momentum de peso aos 365 dias; D: Índice momentum de ganho de peso aos 365 dias; E: Índice de Kleiber aos 450 dias; F: Perímetro escrotal aos 450 dias; G: Índice momentum de peso aos 450 dias; H: Índice momentum de ganho de peso aos 450 dias; I: Area de olho de lombo; J: Espessura de gordura subcutânea; K: Espessura de gordura subcutânea na garupa; L: Marmoreio.






Fonte: Autor/2023.


Recuperando os valores reais para os grupos criados com base nos dados preditos via machine learning, observou-se que o grupo superior 10% apresentaram maior valor médio e menor variância entre seus indivíduos (Figura 18), com destaques para AOL e os índices momentum de pesos aos 365 e 450 dias.

Já menores diferenças foram observadas para o MAR, no entanto, pode-se estar relacionado com a menor quantidade de dados utilizados. Todavia, importante ressaltar que o MAR é um dos principais determinantes da qualidade da carcaça e, conseqüentemente, do seu preço (Alam et al., 2013). Baseado nisso, sugere-se investir em novos dados para buscar a criação acurada de um algoritmo para predição dessa característica.


Figura 18- Dispersão dos valores reais em relação aos grupos criados com base nos dados preditivos. A: Índice de Kleiber aos 365 dias; B: Perímetro escrotal aos 365 dias; C: Índice momentum de peso aos 365 dias; D: Índice momentum de ganho de peso aos 365 dias; E: Índice de Kleiber aos 450 dias; F: Perímetro escrotal aos 450 dias; G: Índice momentum de peso aos 450 dias; H: Índice momentum de ganho de peso aos 450 dias; I: Área de olho de lombo; J: Espessura de gordura subcutânea; K: Espessura de gordura subcutânea na garupa; L: Marmoreio.




C




D




E




F




G



H





Fonte: Autor/2023.

O mercado de carne premium de alta qualidade e alto retorno é amplamente impulsionado por características de qualidade alimentar como o marmoreio, maciez e suculência, além de animais com alto potencial de produção (crescimento, peso) (SHAHINFAR et al., 2020). Assim, nosso resultado é promissor, uma vez que, indica a possibilidade de discriminar os grupos de animais baseado em diferentes indicadores importantes para a tendência do mercado em modo antecipado.

Na produção de bovinos, estudos vem avançando na utilização de aprendizagem de máquinas, e trazendo promissores resultados, como por exemplo: Lee et al. (2020) que utilizou essa ferramenta para prever o peso da carcaça baseado em medidas corporais, enquanto que Alonso et al. (2015) utilizou o peso para o mesmo objetivo; Cominotte et al. (2020) que utilizaram projeções para estrutura latentes para reduzir a quantidade de fatores em cada

uma das fases do crescimento do animal; Nucci et al. (2020) usaram para estimar a gordura da carcaça bovina em fase de terminação.

Alonso et al. (2015) através do desenvolvimento de uma função para a predição do peso de carcaça para bovinos de corte da raça conseguiram prever os pesos das carcaças 150 dias antes do dia do abate. Olejnik et al. (2022) descreveram que a incorporação de máquina de aprendizagem na avicultura, permitiu detectar de modo automático o peso, bem como os estágios de desenvolvimento do animal, o que possibilitou proceder com um fornecimento adequado de alimento, além de monitorar o efeito desta alimentação sobre o desempenho.

No presente estudo foi discriminado 10% superiores e inferiores, porém caso o objetivo do produtor seja apenas identificar um percentual de animais a serem descartados, recomenda-se aumentar o percentual inferior de acordo com a taxa pretendida. Importante ressaltar que na pecuária de corte tradicional, muitas vezes as decisões são baseadas apenas na experiência do produtor, com isso, sugere-se que nenhum extremo comumente é desejável.

Nesse sentido, o pecuarista deve estar atento na interpretação dos resultados, haja vista os requisitos de manter, porque bovinos muito pequenos, apesar da baixa necessidade de manutenção, geram filhos com menor potencial de desenvolvimento e/ou crescimento, ao passo que muito grandes, apesar do potencial superior de crescimento transmitido ao filho, pode possuir uma produtividade reduzida devido a maior necessidade de manutenção (MOTA et al., 2014).


Para todas as fases, apenas os dois primeiros componentes principais foram suficientes para explicar 99% da variação entre os grupos. Em ordem de importância nas fases 1 e 2, observou-se que o IM reteve maior autovalor, enquanto índice de Kleiber menor contribuição (Figura 6 A e B).

Isso é um resultado interessante, uma vez que esse índice, foi o que melhor ajustou de acordo com os critérios usados na predição. Para fase 3, AOL foi a variável que reteve maior autovalor, contribuindo com mais de 90% da variação nessa fase (Figura 19 C).


Figura 19 - Importância das variáveis entre as fases para explicar a variação entre os grupos. A: fase 1; B: fase 2; C: fase 3. A: Índice de Kleiber aos 365 dias; B: Perímetro escrotal aos 365 dias; C: Índice momentum de peso aos 365 dias; D: Índice momentum de ganho de peso aos 365 dias; E: Índice de Kleiber aos

450 dias; F: Perímetro escrotal aos 450 dias; G: Índice momentum de peso aos 450 dias; H: Índice momentum de ganho de peso aos 450 dias; I: Área de olho de lombo; J: Espessura de gordura subcutânea; K: Espessura de gordura subcutânea na garupa; L: Marmoreio.


A



B



C




Fonte: Autor/2023.

Através do biplot (Figura 7) pode-se notar que na fase 1 e 2 os grupos formados estão distribuídos de tal modo que é possível destacar o grupo superior 10%, no qual para todas as variáveis, seu valor é no sentido positivo, e o inverso pode ser visto para o grupo inferior 10%.


Baseado na árvore geradora mínima (minimum spanning tree) da análise de componentes principais, nessa fase o grupo intermediário ficou mais próximo do grupo inferior 10%. O mesmo comportamento é visto na fase 3, todavia, o grupo intermediário é mais próximo do grupo superior 10%.

Figura 20 - Biplot entre os grupos discriminados e as variáveis objetivadas na fase 1 (A), fase 2 (B) e fase 3 (C). A: Índice de Kleiber aos 365 dias; B: Perímetro escrotal aos 365 dias; C: Índice momentum de peso aos 365 dias; D: Índice momentum de ganho de peso aos 365 dias; E: Índice de Kleiber aos 450 dias; F: Perímetro escrotal aos 450 dias; G: Índice momentum de peso aos 450 dias; H: Índice momentum de ganho de peso aos 450 dias; I: Área de olho de lombo; J: Espessura de gordura subcutânea; K: Espessura de gordura subcutânea na garupa; L: Marmoreio.


A



B



C



Fonte: Autor/2023.

Um outro resultado a ser explorado, é que através da análise de predição utilizando medidas de crescimento, foi suficiente para prever as características de ultrassonografia da carcaça. Díez et al. (2003) fizeram um confronto entre ~~is~~ algoritmos de machine learning contra uma abordagem de regressão linear para classificar carcaças usando uma ampla gama de atributos de conformação de raças de carne espanholas com vários cenários em termos de disponibilidade de diferentes atributos para os modelos, e encontraram como resultado, que os

algoritmos de machine learning sempre superaram a regressão linear. Kvam e Kongsro (2017), encontraram ao utilizar a machine learning para prever a gordura intramuscular em 303 suínos a partir de imagens de ultrassom, uma correlação de 82% para gordura intramuscular <6%.

Em geral, os resultados podem ser explorados em diversos modos, como por exemplo a mudança do tipo de manejo alimentar como o direcionamento para sistema de produção (extensivo, semiextensivo ou intensivo) na busca de ganho compensatório e homogeneização dos lotes; por exemplo, Pomar e Remus (2019), utilizando análise de imagens visuais baseadas em visão de máquina para monitorar o peso corporal puderam avaliar as alocações de ração apropriadas aos animais, otimizando o sistema de produção.

Uma continuação desse estudo com um número maior de animais, além de outros métodos de aprendizagem de máquinas são necessários para confrontar os resultados e consequentemente disponibilizar essa tecnologia aos pecuaristas.

3.4 Conclusão

A metodologia aplicada tem potencial com acurácia satisfatória para discriminar antecipadamente grupos de animais baseado no seu desempenho para diversos indicadores (crescimento, eficiência energética e carcaça). Portanto, torna-se promissora para ser aplicada como uma ferramenta adicional para tomada de decisão e obtenção de maiores ganhos na pecuária.

3.5 Refências Bibliográficas

Associação Brasileira das Indústrias Exportadoras de Carne (ABIEC). (2022). **Beef Report Perfil da Pecuária no Brasil**. <http://abiec.com.br/publicacoes/beef-report-2022/>. Acesso em 10 de agosto de 2023.

ADAM, G.; RAMPASEK, L.; SAFIKHANI, Z.; SMIRNOV, P.; HAIBE-KAINS, B.; GOLDENBERG, A. Machine learning approaches to drug response prediction: challenges and recent progress. **Nature partner journals Precision oncology**, Londres, v. 4, p. 1-10, 2020. Doi: <https://doi.org/10.1038/s41698-020-0109-x>.

ADESOGAN, A. T.; HAVELAAR, A. H.; MCKUNE, S. L.; EILITTA, M.; DAHL, G. E. Animal source foods: Sustainability problem or malnutrition and sustainability solution? Perspective matters. **Global Food Security**, Amsterdã, v. 25, p. 100325,

2020. Doi: <https://doi.org/10.1016/j.gfs.2020.100325>.

ALAM, M.; CHO, K. H.; LEE, S. S.; CHOY, Y. H.; KIM, H. S.; CHO, C. I.; CHOI, T. J. Effect of carcass traits on carcass prices of holstein steers in Korea. **Asian-Australasian Journal of Animal Sciences**, Seul, v. 26, n. 10, p. 1388-1398, 2013. Doi: <https://doi.org/10.5713/ajas.2013.13112>.

ALONSO, J.; VILLA, A.; BAHAMONDE, A. Improved estimation of bovine weight trajectories using Support Vector Machine Classification. **Computers and Electronics in Agriculture**, Amsterdã, v. 110, p. 36–41, 2015. Doi: <https://doi.org/10.1016/j.compag.2014.10.011>.

ALONSO, J.; CASTAÑÓN, Á. R.; BAHAMONDE, A. Support Vector Regression to predict carcass weight in beef cattle in advance of the slaughter. **Computers and Electronics in Agriculture**, Amsterdã, v. 91, p. 116–120, 2013. Doi: <https://doi.org/10.1016/j.compag.2012.12.005>.

ANCP - Associação Nacional de Criadores e Pesquisadores. **Características avaliadas**. Ribeirão Preto: ANCP, 2023. Disponível em: <https://www.ancp.org.br/programas/conceitosbasicos/caracteristicas-avaliadas/>. Acesso em: 10 ago. 2023.

ARCHER, J. A.; BARWICK, S. A.; GRASER, H. U. Economic evaluation of beef cattle breeding schemes incorporating performance testing of young bulls for feed intake. **Australian Journal of Experimental Agriculture**, Collingwood, v. 44, n. 5, p. 393-404, 2004. Doi: <https://doi.org/10.1071/EA02131>.

BASARAB, J. A.; COLAZO, M. G.; AMBROSE, D. J.; NOVAK, S.; MCCARTNEY, D.; BARON, V. S. Residual feed intake adjusted for backfat thickness and feeding frequency is independent of fertility in beef heifers. **Canadian Journal of Animal Science**, Ottawa, v. 91, n. 4, p. 573-584, 2011. Doi: <https://doi.org/10.4141/CJAS2011-001>.

BERRY, D. P.; WALL, E.; PRYCE, J. E. Genetics and genomics of reproductive performance in dairy and beef cattle. **Animal**, Cambridge, v. 8, n. 1, p. 105–121, 2014. Doi: <https://doi.org/10.1017/S175173111400030X>.

BOHANEK, M.; BORŠTNAR, M. K.; ROBNIK-ŠIKONJA, M. Explaining machine learning models in sales predictions. **Expert Systems with Applications**, Oxford, v. 71, p. 416–428, 2017. Doi: <https://doi.org/10.1016/j.eswa.2016.11.010>.

BREIMAN, L.; FRIEDMAN, J.; OLSHEN, R.; STONE, C. **Classification and Regression Trees**. Belmont: Wadsworth, 1984.

COMINOTTE, A.; FERNANDES, A. F. A.; DOREA, J. R. R.; ROSA, G. J. M.; LADEIRA, M. M.; VAN CLEEF, E. H. C. B.; PEREIRA, G. L.; BALDASSINI, W. A.; MACHADO NETO, O. R. Automated computer vision system to predict body weight and average daily gain in beef cattle during growing and finishing phases. **Livestock Science**, Amsterdã, v. 232, p. 103904, 2020. Doi: <https://doi.org/10.1016/j.livsci.2019.103904>.

COUTINHO, C. C.; MERCADANTE, M. E. Z.; JORGE, A. M.; PAZ, C. C. P.; EL FARO, L.; MONTEIRO, F. M. Growth curves of carcass traits obtained by ultrasonography in three lines of Nellore cattle selected for body weight. **Genetics and Molecular Research**, Ribeirão Preto, v. 14, n. 4, p. 14076-14087, 2015. Doi: <https://doi.org/10.4238/2015.October.29.17>.

DELGADO, C.; ROSEGRANT, M.; STEINFELD, H.; EHUI, S.; COURBUIIS, C. Livestock to 2020: the next food revolution. **Outlook on Agriculture**, Londres, v. 30, n. 1, p. 27–29, 2001. Doi: <https://doi.org/10.5367/000000001101293409>.

DICK, M.; SILVA, M. A.; SILVA, R. R. F.; FERREIRA, O. G. L.; MAIA, M. S.; LIMA, S. F.; PAIVA NETO, V. B.; DEWES, H. Environmental impacts of Brazilian beef cattle production in the Amazon, Cerrado, Pampa, and Pantanal biomes. **Journal of Cleaner Production**, Oxford, v. 311, p. 127750, 2021. Doi: <https://doi.org/10.1016/j.jclepro.2021.127750>.

DIEZ, J.; ALBERTI, P.; RIPOLL, G.; LAHOZ, F.; FERNÁNDEZ, I.; OLLETA, J. L.; PANEA, B.; SAÑUDO, C.; BAHAMONDE, A.; GOYACHE, F. Using machine learning procedures to ascertain the influence of beef carcass profiles on carcass conformation scores. **Meat Science**, Oxford, v. 73, n. 1, p. 109-115, 2006. Doi: <https://doi.org/10.1016/j.meatsci.2005.11.004>.

DING, M. Q.; CHEN, L.; COOPER, G. F.; YOUNG, J. D.; LU, X. Precision oncology beyond targeted therapy: combining omics data with machine learning matches the majority of cancer cells to effective therapeutics. **Molecular Cancer Research**, Philadelphia, v. 16, n. 2, p. 269–278, 2018. Doi: <https://doi.org/10.1158/1541-7786.MCR-17-0378>.

DISKIN, M. G.; KENNY, D. A. Managing the reproductive performance of beef cows. **Theriogenology**, Nova York, v. 86, p. 379-387, 2016. Doi: <https://doi.org/10.1016/j.theriogenology.2016.04.052>.

FANG, K.; SHEN, C.; KIFER, D.; YANG, X. Prolongation of SMAP to Spatiotemporally Seamless Coverage of Continental U.S. Using a Deep Learning Neural Network. **Geophysical Research Letters**, Washington, v. 44, n. 21, p. 11030–11039, 2017. Doi: <https://doi.org/10.1002/2017GL075619>.

FEI, Y.; GAO, K.; HU, J.; TU, J.; LI, W.; WANG, W.; ZONG, G. Predicting the incidence of portosplenomesenteric vein thrombosis in patients with acute pancreatitis using classification and regression tree algorithm. **Journal of Critical Care**, Nova York, v. 39, p. 124-130, 2017. Doi: <https://doi.org/10.1016/j.jcrc.2017.02.011>.

FERRAZ, J. B. S.; FELÍCIO, P. E. Production systems – An example from Brazil. **Meat Science**, Oxford, v. 84, n. 2, p. 238-243, 2010. Doi: <https://doi.org/10.1016/j.meatsci.2009.06.006>.

GHAFOURI-KESBI, F.; ABBASI, M. A.; AFRAZ, F.; BABAEI, M.; BANEH, H.; ARPANAHI, R. A. Genetic analysis of growth rate and Kleiber ratio in Zandi sheep.

Tropical Animal Health and Production, Edimburgo, v. 43, n. 6, p. 1153-1159, 2011. Doi: <https://doi.org/10.1007/s11250-011-9817-6>.

GOLDBERG, V.; RAVAGNOLO, O. Description of the growth curve for Angus pasture-fed cows under extensive systems. **Journal of Animal Science**, Champaign, v. 93, n. 9, p. 4285–4290, 2010. Doi: <https://doi.org/10.2527/jas.2014-8742>.

HALLAK, R.; PEREIRA FILHO, A. J. Metodologia para análise de desempenho de simulações de sistemas convectivos na região metropolitana de São Paulo com o modelo ARPS: sensibilidade a variações com os esquemas de adoção e assimilação de dados. **Revista Brasileira de Meteorologia**, São José dos Campos, v. 26, n. 4, p. 591-608, 2011. Doi: <https://doi.org/10.1590/S0102-77862011000400010>.

HIGGS, J. D. The changing nature of red meat: 20 years of improving nutritional quality. **Trends in Food Science & Technology**, Cambridge, v. 11, n. 3, p. 85-95, 2000. Doi: [https://doi.org/10.1016/S0924-2244\(00\)00043-4](https://doi.org/10.1016/S0924-2244(00)00043-4).

KVAM, J.; KONGSRO, J. In vivo prediction of intramuscular fat using ultrasound and deep learning. **Computers and Electronics in Agriculture**, Amsterdã, v. 142, p. 521-523, 2017. Doi: <https://doi.org/10.1016/j.compag.2017.09.011>.

LEE, D. H.; LEE, S. H.; CHO, B. K.; WAKHOLI, C.; SEO, Y. W.; CHO, S. H.; KANG, T. H.; LEE, W. H. Estimation of carcass weight of hanwoo (Korean native cattle) as a function of body measurements using statistical models and a neural network. **Asian-Australasian Journal of Animal Sciences**, Seul, v. 33, n. 10, p. 1633–1641, 2020. Doi: <https://doi.org/10.5713/ajas.19.0660>.

LIAKOS, K. G.; BUSATO, P.; MOSHOU, D.; PEARSON, S.; BOCHTIS, D. Machine Learning in Agriculture: A Review. **Sensors**, Basileia, v. 18, n. 8, p. 2674, 2018. Doi: <https://doi.org/10.3390/s18082674>.

MACKOWIAK, S. D.; ZAUBER, H.; BIELOW, C.; THIEL, D.; KUTZ, K.; CALVIELLO, L.; MASTROBUONI, G.; RAJEWSKY, N.; KEMPA, S.; SELBACH, M.; OBERMAYER, B. Identification and analysis of conserved small ORFs in animals. **Genome Biology**, Londres, v. 16, n. 1, p. 179, 2015. Doi: <https://doi.org/10.1186/s13059-015-0741-0>.

MACNEIL, M. D.; NORTHCUTT, S. L. National cattle evaluation system for combined analysis of carcass characteristics and indicator traits recorded by using ultrasound in Angus cattle. **Journal of Animal Science**, Champaign, v. 86, n. 10, p. 2518-2524, 2008. Doi: <https://doi.org/10.2527/jas.2008-1033>.

MALHADO, C. H. M.; MALHADO, A. C. M.; MARTINS FILHO, R.; CARNEIRO, P. L. S.; PALA, A.; CARRILLO, J. A. Age at first calving of Nellore cattle in the semi-arid region of northeastern Brazil using linear, threshold, censored and penalty models. **Livestock Science**, Amsterdã, v. 154, n. 1-3, p. 28–33, 2013. Doi: <https://doi.org/10.1016/j.livsci.2013.02.023>.

MOTTET, A.; DE HAAN, C.; FALCUCCI, A.; TEMPIO, G.; OPIO, C.; GERBER, P. Livestock: On our plates or eating at our table? A new analysis of the feed/food debate. **Global Food Security**, Amsterdã, v. 14, p. 1-8, 2017. Doi: <https://doi.org/10.1016/j.gfs.2017.01.001>.

OLEJNIK, K.; POPIELA, E.; OPALINSKI, S. Emerging Precision Management Methods in Poultry Sector. **Agriculture**, Basileia, v. 12, n. 5, p. 718, 2022. Doi: <https://doi.org/10.3390/agriculture12050718>.

PEREIRA, P. M. C. C.; VICENTE, A. F. R. B. Meat nutritional composition and nutritive role in the human diet. **Meat Science**, Oxford, v. 93, n. 3, p. 586-592, 2013. DOI: <https://doi.org/10.1016/j.meatsci.2012.08.018>.

POMAR, C.; REMUS, A. Precision pig feeding: a breakthrough toward sustainability. **Animal Frontiers**, Champaign, v. 9, n. 2, p. 52-59, 2019. Doi: <https://doi.org/10.1093/af/vfz006>.

POPPI, D. P.; QUIGLEY, S. P.; SILVA, T. A. C. C.; MCLENNAN, S. R. Challenges of beef cattle production from tropical pastures. **Revista Brasileira de Zootecnia**, Viçosa, v. 47, p. e20160419, 2018. Doi: <https://doi.org/10.1590/rbz4720160419>.

REZENDE, M. P. G.; MALHADO, C. H. M.; BIFFANI, S.; CARNEIRO, P. L. S.; BOZZI, R. Genetic diversity derived from pedigree information and estimation of genetic parameters for reproductive traits of Limousine and Charolais cattle raised in Italy. **Italian Journal of Animal Science**, Bologna, v. 19, n. 1, p. 762-771, 2020. Doi: <https://doi.org/10.1080/1828051X.2020.1793796>.

REZENDE, M. P. G.; MALHADO, C. H. M.; BIFFANI, S.; CARRILLO-TABAKMAN, J. A.; FABBRI, M. C.; CROVETTI, A.; CARNEIRO, P. L. S.; BOZZI, R. Heritability and genetic correlation of body weight and Kleiber ratio in Limousin and Charolais beef cattle breeds. **Animal**, Cambridge, v. 16, n. 5, p. 100528, 2022. Doi: <https://doi.org/10.1016/j.animal.2022.100528>.

ROBERTS, A. J.; PETERSEN, M. K.; FUNSTON, R. N. Can we build the cowherd by increasing longevity of females? **Journal of Animal Science**, Champaign, v. 93, n. 9, p. 4235-4243, 2015. Doi: <https://doi.org/10.2527/jas.2014-8785>.

ROMERO, M. P.; CHANG, Y.; BRUNTON, L. A.; PARRY, J.; PROSSER, A.; UPTON, P.; REES, E.; TEARNE, O.; ARNOLD, M.; STEVENS, K.; DREWE, J. A. Decision tree machine learning applied to bovine tuberculosis risk factors to aid disease control decision making. **Preventive Veterinary Medicine**, Amsterdã, v. 175, p. 104860, 2020. Doi: <https://doi.org/10.1016/j.prevetmed.2019.104860>.

SAMUEL, A. L. Some Studies in Machine Learning Using the Game of Checkers. **International Business Machines Corporation Journal of Research and Development**, Armonk, v. 44, n. 1.2, p. 206-226, 1959. Doi: <https://doi.org/10.1147/rd.441.0206>.

SHAHINFAR, S.; AL-MAMUN, H. A.; PARK, B.; KIM, S.; GONDRO, C. Prediction of marbling score and carcass traits in Korean Hanwoo beef cattle using machine

learning methods and synthetic minority oversampling technique. **Meat Science**, Oxford, v. 161, p. 107997, 2020. Doi: <https://doi.org/10.1016/j.meatsci.2019.107997>.

TAKAHASHI, K.; KIM, K.; OGATA, T.; SUGANO, S. Tool-body assimilation model considering grasping motion through deep learning. **Robotics and Autonomous Systems**, Amsterdã, v. 91, p. 115-127, 2017. Doi: <https://doi.org/10.1016/j.robot.2016.11.014>.

TEDESCHI, L. O. Assessment of the adequacy of mathematical models. **Agricultural Systems**, Amsterdã, v. 89, n. 2-3, p. 225-247, 2006. DOI: <https://doi.org/10.1016/j.agsy.2005.08.010>.

TEDESCHI, L. O.; BOIN, C.; NARDON, R. F.; LEME, P. R. Estudo da curva de crescimento de animais da raça Guzerá e seus cruzamentos alimentados a pasto, com e sem suplementação, análise e seleção das funções não-lineares. **Revista Brasileira de Zootecnia**, Viçosa, v. 29, n. 2, p. 630-637, 2000. Doi: <https://doi.org/10.1590/S1516-35982000000200040>.

WANG, Y.; ZHAO, Y.; THERNEAU, T. M.; ATKINSON, E. J.; TAFTI, A. P.; ZHANG, N.; AMIN, S.; LIMPER, A. H.; KHOSLA, S.; LIU, H. Unsupervised machine learning for the discovery of latent disease clusters and patient subgroups using electronic health records. **Journal of Biomedical Informatics**, Amsterdã, v. 102, p. 103364, 2020. Doi: <https://doi.org/10.1016/j.jbi.2019.103364>.

XIONG, Y.; CONDOTTA, I. C. F. S.; MUSGRAVE, J. A.; BROWN-BRANDL, T. M.; MULLINIKS, J. T. Estimating body weight and body condition score of mature beef cows using depth images. **Translational Animal Science**, Cary, v. 7, n. 1, p. txad085, 2023. Doi: <https://doi.org/10.1093/tas/txad085>.

YOKOO, M. J.; ALBUQUERQUE, L. G.; LOBO, R. B.; BEZERRA, L. A. F.; ARAÚJO, F. R. C.; SILVA, J. A. V.; SAINZ, R. D. Genetic and environmental factors affecting ultrasound measures of longissimus muscle area and backfat thickness in nelore cattle. **Livestock Science**, Amsterdã, v. 117, n. 2-3, p. 147-154, 2008. Doi: <https://doi.org/10.1016/j.livsci.2007.12.008>.

ZHOU, C.; LIN, K.; XU, D.; CHEN, L.; GUO, Q.; SUN, C.; YANG, X. Near infrared computer vision and neuro-fuzzy model-based feeding decision system for fish in aquaculture. **Computers and Electronics in Agriculture**, Amsterdã, v. 146, p. 114–124, 2018. Doi: <https://doi.org/10.1016/j.compag.2018.01.020>

CAPÍTULO 4 – CONSIDERAÇÕES FINAIS

O ciclo completo da bovinocultura de corte é longo quando comparado a outras espécies comerciais como suínos, ovinos, aves e peixe. Além disso, o custo de manejo nutricional, reprodutivo, veterinário entre outros, torna de certo modo, essa atividade com risco de perdas financeiras quando estratégias de manejos não são elaboradas corretamente. A margem financeira do pecuarista depende principalmente do desempenho zootécnico de seu rebanho.

Esse desempenho pode ser visto por indicadores fenotípicos por meio do crescimento, capacidade reprodutiva e qualidade da carcaça. Nesse sentido, nos observamos que a aplicação de inteligência artificial como uso de métodos de ML na bovinocultura de corte pode contribuir para decisões estratégicas de manejo antecipadas. Todavia, apesar de ser promissor nossos resultados, sugere-se mais estudos para consolidar os modelos e identificar de maneira mais acurada o melhor método entre os apresentados.