

Metodologias para estimativa de peso de bovinos Nelore em sistemas extensivos a partir de pesagens diárias



**Empresa Brasileira de Pesquisa Agropecuária
Embrapa Agricultura Digital
Ministério da Agricultura, Pecuária e Abastecimento**

DOCUMENTOS 186

Metodologias para estimativa de peso de bovinos Nelore em sistemas extensivos a partir de pesagens diárias

*Roberto Hiroshi Higa
Glauber José Vaz
Adauto Luiz Mancini
Caroline Carvalho de Oliveira
Kleber Xavier Sampaio de Souza
Gabriela Correia Vechini
Eduardo Antonio Speranza*

Embrapa Agricultura Digital
Campinas, SP
2022

Embrapa Agricultura Digital
Av. Dr. André Tosello, nº 209 - Campus da Unicamp,
Barão Geraldo - Campinas, SP
CEP. 13083-886 - Fone: +55 (19) 3211-5700

www.embrapa.br/agricultura-digital
www.embrapa.br/fale-conosco/sac

Comitê Local de Publicações
da Unidade Responsável

Presidente
Carla Geovana do Nascimento Macário

Secretário-Executivo
Maria Fernanda Moura

Membros
Adriana Farah Gonzalez, Alexandre de Castro, Carla Cristiane Osawa, Debora Pignatari Drucker, Ivan Mazoni, João Camargo Neto, João Francisco Gonçalves Antunes, Magda Cruciol

Revisão de texto
Adriana Farah Gonzalez

Normalização bibliográfica
Carla Cristiane Osawa

Projeto gráfico da coleção
Carlos Eduardo Felice Barbeiro

Editoração eletrônica
Letícia Mathias do Amaral Campos

Imagem da capa
Letícia Mathias do Amaral Campos

1ª edição
Publicação digital (2022): PDF

Todos os direitos reservados.

A reprodução não autorizada desta publicação, no todo ou em parte, constitui violação dos direitos autorais (Lei nº 9.610).

Dados Internacionais de Catalogação na Publicação (CIP)

Embrapa Agricultura Digital

Metodologias para estimativa de peso de bovinos Nelore em sistemas extensivos a partir de pesagens diárias / Roberto Hiroshi Higa ... [et al.]. – Campinas : Embrapa Agricultura Digital, 2022.
PDF (32 p.) : il. color. - (Documentos / Embrapa Agricultura Digital, ISSN 2764-2488 ; 186)

1. Bovino de corte. 2. Gado Nelore. 3. Pesagem. I. Higa, Roberto Hiroshi. II. Embrapa Agricultura Digital. III. Série.

CDD (21. ed.) 636.213

Autores

Roberto Hiroshi Higa

Engenheiro eletricitista, doutor em Engenharia Elétrica, pesquisador da Embrapa Agricultura Digital, Campinas, SP

Glauber José Vaz

Cientista da Computação, mestre em Ciência da Computação, analista da Embrapa Agricultura Digital, Campinas, SP

Adauto Luiz Mancini

Cientista da Computação, mestre em Ciência da Computação, pesquisador da Embrapa Agricultura Digital, Campinas, SP

Caroline Carvalho de Oliveira

Zootecnista, Ph.D em Ciências Agrárias, bolsista de estímulo à inovação na Embrapa Gado de Corte, Campo Grande, MS

Kleber Xavier Sampaio de Souza

Engenheiro eletricitista, doutor em Engenharia Elétrica, pesquisador da Embrapa Agricultura Digital, Campinas, SP

Gabriela Correia Vechini

Bacharel em Estatística, Pesquisadora do Centro de Pesquisa e Desenvolvimento em Telecomunicações (CPQD), Campinas, SP

Eduardo Antonio Speranza

Cientista da Computação, doutor em Ciência da Computação, analista da Embrapa Agricultura Digital, Campinas, SP

Apresentação

Este trabalho contempla parte dos resultados alcançados no projeto de pesquisa “Sistema Integrado de IoT e IA para monitoramento de indicadores de produtividade, ambientais e de bem-estar animal em sistemas de Integração Lavoura-Pecuária-Floresta (ILPF)”, uma parceria estabelecida entre a Embrapa, o Centro de Pesquisa e Desenvolvimento em Telecomunicações (CPQD) e a Huawei do Brasil Telecomunicações.

A estratégia de produção ILPF, que tem o objetivo de integrar diferentes sistemas de produção agrícola, pecuário e florestal em uma mesma área, vem crescendo ao longo dos anos e, atualmente, compreende cerca de 17 milhões de hectares das áreas sob uso agropecuário no Brasil. Com isso, é possível observar uma tendência na adoção de Tecnologias de Informação e Comunicação (TICs) por parte dos produtores para auxílio na gestão e tomada de decisão específicas para esse tipo de sistema.

Nesse projeto de pesquisa, os pesquisadores e analistas da Embrapa da área de inteligência artificial tiveram a oportunidade de trabalhar com dados provenientes de diferentes sistemas IoT considerados como essenciais para o monitoramento diário do ganho de peso e bem-estar animal, como as balanças de passagem automatizadas. Assim, houve a possibilidade de validar e desenvolver modelos para estimativa de peso de bovinos Nelore em sistemas extensivos.

As principais contribuições deste documento estão relacionadas ao uso de diferentes abordagens presentes na literatura para estimar o peso futuro dos animais. Os resultados ainda são preliminares, mas mostram que é possível estimar o peso futuro dos bovinos com boa acurácia, desde que os dados fornecidos sejam confiáveis e representem a realidade que ocorre em campo.

Stanley Robson Medeiros de Oliveira
Chefe-geral da Embrapa Agricultura Digital

Sumário

Introdução..... 8

Material e Métodos 12

Resultados..... 17

Discussão 25

Conclusão..... 29

Referências 31

Introdução

A criação extensiva de bovinos de corte é considerada uma das mais complexas e desafiadoras das cadeias produtivas do agronegócio brasileiro (Sversutti; Yada, 2019). Os sistemas extensivos utilizam áreas de pastagens nativas e cultivadas como fonte de alimentos, o que resulta em uma grande variabilidade na produção de carne, limitados por fatores como clima, solo, manejo animal e da pastagem, grau de tecnificação, entre outros (Cezar et al., 2005).

A Integração Lavoura-Pecuparia-Floresta (ILPF) é um sistema extensivo de manejo que integra componentes de produção agropecuária e florestal em uma área comum, por meio de rotações e sucessões, onde cada um dos componentes tem a sua devida importância e provoca efeito sobre os outros. Inicialmente, o ILPF foi utilizado para recuperação de pastagens degradadas e, ao mesmo tempo, preservação do meio ambiente. Atualmente, é uma das tecnologias adotadas para redução da emissão de gases de efeito estufa (GEE) na agricultura (Herrmann; Rodrigues, 2021).

Nos últimos anos, várias iniciativas em pesquisa, desenvolvimento e inovação (PD&I) têm sido realizadas para promover a adoção da ILPF no Brasil. A Embrapa é pioneira nessas iniciativas e viabilizou, em 2018, a criação da associação Rede ILPF, que envolve grandes empresas e cooperativas do setor privado. Considerando o know-how da Embrapa em ILPF e as leis de incentivo fiscal existentes no Brasil para que empresas da iniciativa privada invistam em PD&I, em 2021 foi firmado um acordo de cooperação técnica entre a Embrapa e as empresas Huawei do Brasil Telecomunicações e o Centro de Pesquisa e Desenvolvimento em Telecomunicações (CPQD). Esse acordo teve como principal objeto a execução conjunta do projeto de pesquisa intitulado “Sistema integrado de IoT e IA para monitoramento de indicadores de produtividade, ambientais e de bem-estar animal em sistemas ILPF”. As atividades executadas neste projeto visam incentivar o uso de tecnologias de sensoriamento baseado em Internet das Coisas (IoT) e de inteligência artificial (IA) em um ambiente rural, para monitoramento em tempo real de indicadores de produtividade, ambiental e bem-estar animal em sistemas ILPF.

Uma unidade demonstrativa do projeto para prova de conceito (PoC) foi instalada no campo experimental “Agrossilvipastoril”, de 18 ha, localizado na Embrapa Gado de Corte, em Campo Grande, MS, com coordenadas centrais (lat, long) S 54°42’26” e O 20°24’52”. Esse campo experimental é composto por três sistemas ILPF distintos: 1) ILPF-28, com integração lavoura-pecuária-floresta contendo 89 árvores por hectare; 2) ILPF-22, com integração lavoura-pecuária-floresta contendo 113 árvores por hectare; e 3) Integração Lavoura-Pecuária (ILP), com integração lavoura-pecuária (não possui árvores). Para o experimento do projeto foram utilizados 32 animais da raça Nelore com idade aproximada de 12 meses, sendo que 12 deles localizados no sistema ILPF-28, 12 no sistema ILPF-22 e 8 no sistema ILP. A ideia dessa distribuição é verificar as diferenças de comportamento dos animais e, conseqüentemente, do seu ganho de peso, durante o período em que lá permanecerem, considerando os benefícios proporcionados pelas florestas com diferentes densidades de árvores em relação a um sistema com ausência dessa componente utilizado como controle.

A arquitetura da plataforma IoT para o PoC realizado durante a execução do projeto (Figura 1) foi definida considerando três tipos de sensores distintos: 1) cabrestos inteligentes, instalados individualmente em cada animal, capazes de coletar informações como temperatura do pelame e frequência cardíaca e respiratória; 2) estações microclimáticas, instaladas individualmente em cada sistema, capazes de coletar informações como temperatura e umidade relativa do ar, velocidade e direção do vento e radiação solar; e 3) balanças de passagem, também instaladas individualmente em cada sistema, capazes de fornecer valores de pesagens diárias para os animais. Todos os sensores definidos para utilização nessa PoC possuem subsistemas IoT disponíveis.

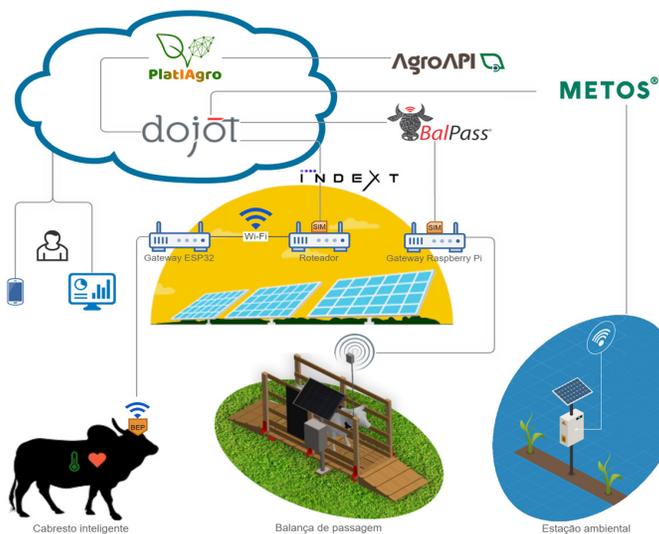


Figura 1. Arquitetura definida para PoC de plataforma IoT para monitoramento de ganho de peso e bem-estar animal em sistemas ILPF.

Fonte: Speranza et al. (2022).

De acordo com a arquitetura definida na Figura 1, os dados obtidos na PoC serão integrados em nuvem a partir da plataforma de IoT dojot (Dojot, 2022). Para tanto, foram desenvolvidos agentes IoT que buscam, em intervalos de tempo pré-definidos, os dados em nuvens privadas das empresas responsáveis pelos sensores utilizados (Speranza et al., 2022). Além da plataforma dojot, o projeto prevê a utilização da Plataforma de inteligência artificial do CPQD (Projeto..., 2022), para treinamento e disponibilização de modelos desenvolvidos no âmbito do projeto; e da plataforma de APIs da Embrapa (AgroAPI) (Vaz et al., 2017), para disponibilização de dados e modelos desenvolvidos pela Embrapa e parceiros e que possam ser utilizados pelo projeto.

A Figura 2 mostra uma imagem da área da unidade demonstrativa, suas divisões e a localização das balanças de passagem, cujos dados coletados foram utilizados para as análises realizadas neste trabalho.



Figura 2. Área experimental “Agrossilvipastoril”, localizada na Embrapa Gado de Corte (Campo Grande, MS), com identificação dos sistemas ILPF-28, ILPF-22 e ILP e localização das balanças de passagem instaladas.

Fonte: Adaptado de Google (2022).

O trabalho teve como principal objetivo estabelecer modelos para a estimativa de peso bovinos da raça Nelore, considerando pesagens diárias obtidas a partir de balanças de passagem instaladas em área experimental, conforme exibido na Figura 2. Para tanto, foram realizados experimentos com diferentes métodos analíticos, com o objetivo de estimar o peso futuro individual de animais para previsão de data de saída do sistema, conforme o objetivo de peso definido pelo produtor.

Considerando a arquitetura descrita na Figura 1, o projeto prevê o desenvolvimento de aplicação web e aplicativo mobile que permitem ao usuário final, além do monitoramento das variáveis relacionadas ao ganho de peso e ao bem-estar animal, uma data futura para que cada animal saia do sistema ou esteja em condições de abate, conforme peso objetivo definido na sua entrada.

Desse modo, o fluxo de dados a ser considerado para essa previsão, tanto para treinamento, quanto para a execução de modelos baseados em regressores, parte da coleta de pesos individuais diários pela balança de passagem, seguindo um fluxo de rede até chegar à Plataforma de IA do CPQD, onde os modelos estão efetivamente implementados.

A Plataforma de IA do CPQD foi utilizada com o objetivo de facilitar a implantação e disponibilizar seu uso para predições. Após a fase de experimentação o modelo é disponibilizado na plataforma, containerizado¹ pela aplicação Seldon², a qual implementa o modelo para ele ser servido como uma API. Essa é acessada por um *endpoint*³ gerado automaticamente. Este *endpoint* é acionado quando um novo peso chega na plataforma **dojot**.

Material e Métodos

Os dados referentes às pesagens diárias dos animais são coletados em campo de maneira automática pelas três balanças de passagem instaladas nos três diferentes sistemas que compõem a área experimental. O modelo utilizado neste experimento é a BalPass®, atualmente comercializada pela Coimma (Coimma, 2022) (Figura 3). A metodologia utilizada por esse modelo de balança permite o acompanhamento da evolução de ganho de peso individual, possibilitando ao produtor controlar o desenvolvimento do rebanho e auxiliar em tomada de decisões referentes ao descarte de animais e mudanças de dieta de acordo com as metas preestabelecidas (Sistema..., 2019). Para seu correto funcionamento, as três balanças desse experimento foram instaladas em locais estratégicos com acesso a bebedouros e cochos de suplementação alimentar, onde os animais passam todos os dias. Independentemente da quantidade de vezes que cada animal, devidamente identificado com chip RFID, passa pela balança em um mesmo dia, o sistema BalPass captura todas as pesagens obtidas (dados brutos). Considerando a arquitetura da plataforma definida na Figura 1, os dados brutos de pesagem dos animais coletados pelas balanças são transmitidos a um *gateway Raspberry* PI ligado à rede 4G. Ao final do dia, os dados são transmitidos para a nuvem do sistema BalPass, onde um algoritmo de inteligência artificial realiza a consolidação dos pesos e fornece apenas um valor de pesagem para cada animal (Rodrigues Filho; Santos Neto, 2013).

¹ **Containerização:** empacotamento do código de software com todos os componentes necessários, como bibliotecas e frameworks, para que fiquem isolados em seu próprio "container".

² **Seldon Technologies Limited**, London, United Kingdom, disponível em: <https://www.seldon.io/>.

³ **Endpoint:** forma de disponibilização de um recurso de uma API



Foto: Camilo Carromeu (Embrapa Gado de Corte)

Figura 3. Balança de passagem BalPass instalada na área experimental da Embrapa Gado de Corte.

Para verificar a qualidade dos dados coletados pelas balanças similares ao exemplar da Figura 3 foi realizada uma análise exploratória dos dados de forma individualizada (por animal). Diferentes metodologias da literatura foram exploradas, com o objetivo de encontrar o ajuste mais adequado para o contexto do projeto.

Metodologia baseada no ajuste de curvas não lineares

Tradicionalmente, o acompanhamento do crescimento dos animais por meio do ganho de peso se dá pelo ajuste de curvas de crescimento expressas por funções não-lineares (Lopes et al., 2016), tais como os modelos propostos por Brody (1945), von Bertalanffy (1957), Gompertz (1825) e Richards (1959), ou pela função logística (Verhulst, 1845), que foram desenvolvidos originalmente não para modelar o crescimento de animais, mas para outros processos de dinâmica populacional. Um aspecto comum a todas essas funções é que apresentam um ganho de peso com trajetória crescente no início e que vai convergindo para um platô quando o animal atinge a fase adulta.

Em geral, essas curvas de crescimento são ajustadas para a modelagem do comportamento médio dos animais, sem considerar particularidades dos ambientes nos quais se encontram ou da sua estratégia de manejo.

Experimento de avaliação

Neste trabalho, avaliou-se o ajuste dos pesos, por animal, obtidos por meio da balança de passagem às curvas acima mencionadas. O código foi desenvolvido na linguagem Python e com o pacote SciPy, que oferece uma coleção de algoritmos matemáticos, inclusive para otimização. O subpacote 'optimize' oferece funções para minimização de funções e inclui ajuste de curvas definidas pelo usuário por meio da função 'curve_fit', baseada no critério de mínimos quadrados. Além disso, também foram analisadas as curvas ajustadas envolvendo não apenas as pesagens obtidas por meio das balanças, mas também os pesos dos animais em seu nascimento e na desmama, registrados manualmente.

Metodologia baseada em filtro de Kalman

Filtros de Kalman (FK) são estimadores de estados de sistemas dinâmicos na presença de ruídos. Utilizando uma representação de sistemas em espaço de estados, ele assimila medidas imprecisas (com ruído) para obter uma estimativa mais precisa para o estado atual, podendo ainda realizar previsões para estados futuros. Esse estimador é implementado como um algoritmo iterativo onde em cada passo uma nova medida é utilizada para atualização dos estados do sistema e as correspondentes medidas de incerteza. O algoritmo opera em duas fases: 1) na primeira fase (previsão), as estimativas correntes dos estados do sistema e as correspondentes estimativas de incerteza são atualizadas, utilizando a medida disponibilizada; e 2) no segundo passo, os estados e estimativas de incerteza são projetados para utilização no próximo passo de iteração. Do ponto de vista computacional, esse algoritmo é bastante atraente, pois seu processamento é muito eficiente e, em termos de memória computacional, apenas o estado anterior precisa ser mantido. Para realização de previsões os mesmos passos do algoritmo são executados, considerando que não existe medida observada. Para mais detalhes, vide referências (Zarchan; Mussoff, 2005; Brown; Hwang, 2012).

Na presente aplicação considera-se um FK com um modelo polinomial de grau 2, Filtro de Kalman Polinomial (FKP), para acompanhar a dinâmica de ganho de peso de bovinos de corte e fazer previsões para um número específico de dias à frente. A ideia por trás dessa abordagem é a utilização de uma

forma quadrática como aproximação para trechos da curva de ganho de peso do animal que correspondam à fase de recria do ciclo de vida de bovinos. Além de funcionar como um filtro, estimando um valor do peso do animal a partir de medidas que incluem ruídos, o FK também pode ser utilizado para predição tanto de dados faltantes (imputação), quanto para um número específico de dias à frente, bem como a obtenção do ganho diário de peso e de sua correspondente variação.

Experimento de avaliação

Neste experimento foi utilizado um conjunto de dados de pesagens diárias, obtidas por meio de duas balanças de passagem (BalPass®) instaladas em um campo experimental da Embrapa Gado de Corte, dedicada a experimentos de ILPF. As coletas foram realizadas entre os dias 17/12/2021 a 31/05/2022, totalizando 166 pesagens para 36 animais incluídos no experimento. Devido à presença de muitos dados faltantes, principalmente na parte final da série, 16 animais (3, 8, 9, 10, 12, 15, 17, 19, 20, 23, 26, 29, 30, 31, 32 e 35) foram eliminados do conjunto de dados original. Os dados dos 20 animais restantes foram submetidos a um FKP, com parâmetros de definição das variâncias ajustados empiricamente. Para definição da variância de processo, utilizou-se um valor de densidade de potência espectral, ϕ_s , igual a $1e_{-6}$ e a variância de sinal, R , igual a 5 kg. Foram utilizados os valores iniciais de estado, $x_0 = [0, 0, 0]^T$, a matriz de covariância do erro $P_0 = \text{diag}([100., 10., 1.])$. Esses valores refletem uma sobreavaliação para as variâncias dos estados do modelo (peso, ganho diário de peso ϕ e variação do ganho diário de peso). Para cada um dos 20 animais que participaram do experimento, as pesagens do dia 0 ao dia 136 foram utilizadas para ajustar os parâmetros do FK (e também prever o correspondente valor mais provável após observar o dado mensurado). O filtro com os parâmetros ajustados foi então utilizado para prever os pesos para os 29 dias restantes (137 a 165). Finalmente, a diferença entre o peso predito e o observado para o dia 165 foi medido e o valor médio para os 20 animais reportados como erro de predição.

Metodologia baseada em Redes Neurais

Rede Neural Multicamadas, do inglês Multi Layer Perceptron (MLP) é uma das ferramentas de aprendizado de máquina disponíveis para a criação de modelos caixa-preta muito úteis para problemas não lineares (Landi et al., 2010). Um modelo caixa-preta significa que não há extração de conhecimento sobre como cada variável de entrada se comporta individualmente no sistema ou em relação às outras variáveis, não se conseguindo obter diretamente informações sobre as propriedades físicas ou biológicas do sistema sendo estudado. Uma rede neural multicamadas contém uma ou mais camadas de neurônios formando um conjunto de variáveis livres (pesos associados a cada conexão entre neurônios e um bias para cada neurônio) que emula o mapeamento de um conjunto de variáveis de entrada para um conjunto de variáveis de saída. Os valores dessas variáveis livres são obtidos por meio de um procedimento iterativo que, utilizando um conjunto de dados de entrada com a saída observada (conjunto de dados de treinamento), ajusta essas variáveis no sentido de reduzir o erro entre as saídas produzidas pela rede neural (predições) e aquelas observadas. A esse processo denomina-se treinamento da rede neural, que no caso da rede neural MLP, pelo fato de o conjunto de dados de treinamento conter tanto os dados de entrada como a saída observada, é denominado treinamento supervisionado.

Na presente aplicação, a rede neural MLP é modelada para predizer o peso de um animal no dia de interesse, utilizando como variáveis preditoras o conjunto de pesagens dos animais até o quarto dia anterior e a idade do animal no dia de interesse.

Experimento de avaliação

Neste experimento, as pesagens dos animais no período entre 17/12/2021 e 30/05/2022 foram usadas nos testes com redes neurais. Os animais do sistema ILPF-22 deixaram de ser pesados a partir de 12/01/2022, quando foram retirados da área experimental. Para cada animal, foram preparados os seguintes conjuntos de dados:

- p1, p
- d, p1, p

- p_4, p_3, p_2, p_1, p
- d, p_4, p_3, p_2, p_1, p

onde p é o peso observado que se deseja prever, d é a idade em dias do animal no dia da pesagem p_1 , p_1 é o peso do dia anterior ao dia de p , p_2 é o peso de dois dias antes, p_3 é o peso de três dias antes, p_4 é o peso de quatro dias antes. Assim, para o conjunto de dados d, p_4, p_3, p_2, p_1, p as tuplas de dados são obtidas com a janela de tempo deslizando com o valor de p_4 inicialmente posicionado na primeira pesagem, sendo incrementado enquanto existir quatro pesagens correspondentes aos dias posteriores do dia da pesagem de p_4 na série de pesagens do animal sendo considerado. Note que para os animais do tratamento ILPF-22 não foram gerados os conjuntos de dados p_4, p_3, p_2, p_1, p e d, p_4, p_3, p_2, p_1, p porque a quantidade de tuplas foi considerada pequena para o treinamento adequado de MLP.

Para avaliar o desempenho da rede neural MLP foi utilizado um procedimento de validação cruzada 10%. Isto significa que o conjunto de dados é dividido em dez partes, nove para treinamento e uma para teste, resultando em dez combinações alternadas de dados de treino e teste. Os experimentos foram realizados utilizando o software Weka (Witten et al., 2011) e o resultado reportado foi a média das avaliações dos dez conjuntos de dados. A regressão linear foi utilizada como *benchmark*.

Resultados

Análise exploratória dos dados

A Figura 4 exibe exemplos de gráficos gerados em que o eixo x representa a idade do animal em dias e o eixo y representa seu peso em Kg. A linha vermelha corresponde à regressão linear dos pontos. Enquanto a Figura 4A exibe o caso de um animal com pesagens dentro daquilo que é esperado, as pesagens apresentadas na Figura 4B exibem um padrão não esperado. Foram identificados inúmeros casos de animais com padrão de pesagens análogo ao apresentado na Figura 4B.

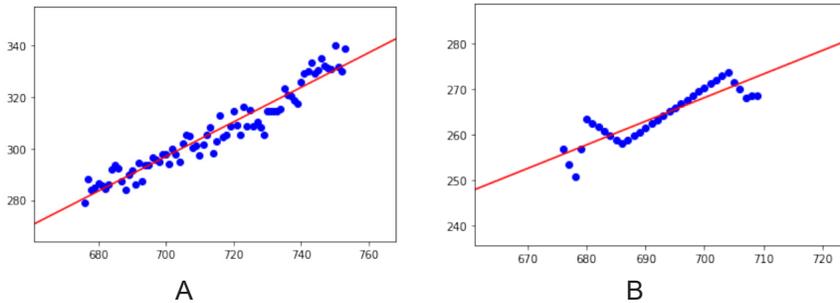


Figura 4. Exemplos de pesos para dois animais, um com padrão de dados esperado (A) e outro com padrão não esperado (B).

Outro fato relevante observado no conjunto de dados é a presença de um conjunto de animais cuja pesagem não foi registrada a partir de 12/01/2022.

Ajuste de curvas não lineares

Foram realizados ajustes dos pesos obtidos por meio da balança de passagem às funções de Brody (1945), Gompertz (1825), von Bertalanffy (1957), Richards (1959) e logística (Verhulst, 1845). Para as funções de Richards e de von Bertalanffy, o algoritmo normalmente não convergiu com os dados do experimento. Para as demais, considerando-se apenas os dados de pesos obtidos pela balança, as curvas na região dos pontos levantados são parecidas, conforme pode ser observado na Figura 5A, que mostra o ajuste das curvas para um certo animal no período que envolve as pesagens. Note que além das funções previamente citadas, também são exibidas no gráfico as curvas para os dados obtidos pela balança, em real data, e para a regressão linear desses pontos. A função Brody tem duas versões, a *optimized brody* e a *fixed brody*, cuja curva sequer aparece na figura. A primeira refere-se à função ajustada aos pesos da balança e a segunda à função com os valores dos parâmetros determinados por Silva et al. (2001). Para esses autores, a função Brody é a que melhor descreve o crescimento de animais Nelore do nascimento aos 550 dias de idade.

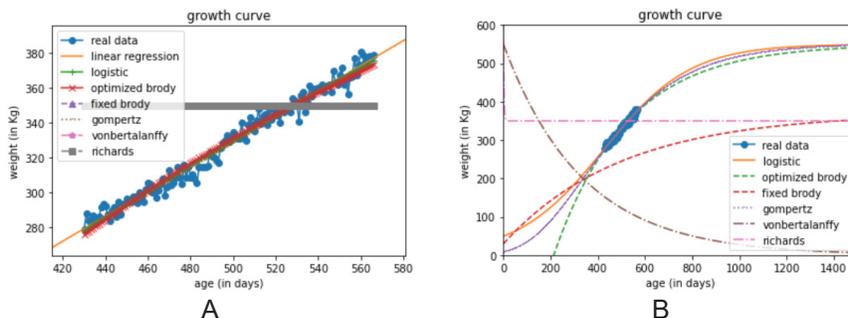


Figura 5. Ajuste das curvas aos pesos obtidos por meio da balança (A) e considerando o período do nascimento até a maturidade (B).

A Figura 5B exibe as mesmas curvas apresentadas na Figura 5A, mas considerando desde o nascimento do animal (dia zero de idade) até sua maturidade, quando se observa um platô.

Esse gráfico também mostra que as curvas ajustadas levam a um peso à maturidade muito semelhante entre as curvas Brody ajustada, Gompertz e logística para esse animal, o que foi bastante comum nos experimentos executados. A função com parâmetros fixos exibiu um comportamento muito diferente das demais, já que ela não se ajusta aos pesos coletados, enquanto as funções de Richards e von Bertalanffy não convergiram.

A Figura 6 mostra o impacto da inserção dos pesos dos animais no nascimento e na desmama nas curvas ajustadas. Observa-se um comportamento mais próximo do que se espera utilizando dados compreendendo todo o ciclo de crescimento dos animais, incluindo os pesos de nascimento e de desmama.

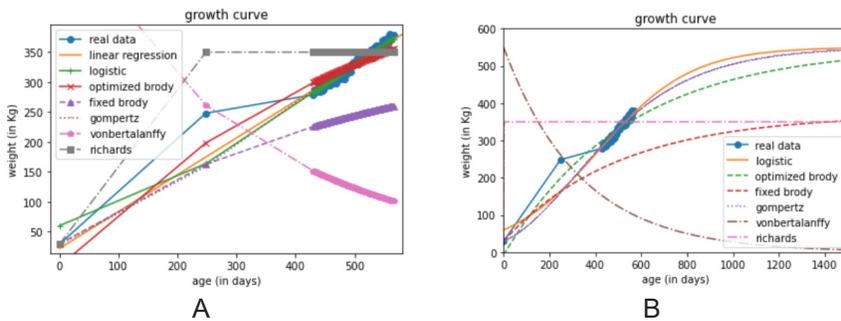


Figura 6. Curvas de crescimento incluindo pesos no nascimento e na desmama, para o período que envolve apenas os pesos da balança (A) e para o período entre o nascimento e a maturidade (B).

Mesmo com a limitação no poder representativo das funções consideradas, a Brody foi selecionada em um primeiro momento por ser a mais indicada na representação de bovinos Nelore de acordo com estudo de Lopes et al. (2016). A Figura 7 mostra a curva Brody com os parâmetros determinados por Silva et. al (2001) (*fixed brody*) comparada à Brody ajustada apenas aos pesos coletados pela balança (*brody without init*) e à Brody ajustada incluindo os pesos de nascimento e de desmama (*optimized brody*). Nessa figura é possível observar mais detalhadamente o impacto produzido pelos pesos de nascimento e desmama no ajuste da função.

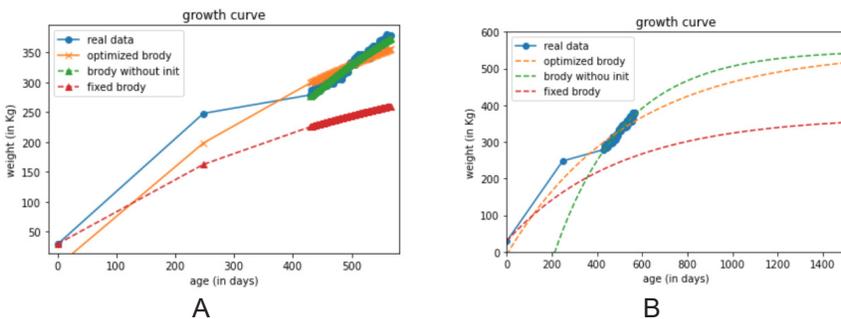


Figura 7. Visualização dos pesos coletados e da função Brody com parâmetros fixos (*fixed brody*), ajustada aos pesos da balança, com inclusão dos pesos de nascimento e de desmama (*optimized brody*) e ajustada apenas aos pesos da balança (*brody without init*). Para o período que envolve apenas os pesos coletados (A) e para o período entre o nascimento e a maturidade (B).

Filtro de Kalman

Um FKP com os parâmetros apresentados na seção Material e Métodos foi utilizado com o conjunto de dados de pesagens correspondentes a cada um dos 20 animais incluídos no experimento. O erro de predição para o dia 165 foi medido, tendo variado de -17.73 kg a 18.32 kg, com média igual a -1.48 kg, desvio padrão igual a 10.27 kg e mediana igual a -3.42 kg. A Figura 8 ilustra um caso (animal 4) em que a predição para o dia 165 é muito boa (erro igual a -1.33 kg). Note que a acurácia da predição depende inteiramente da manutenção da tendência de ganho de peso (taxas de ganho de peso e de variação do ganho de peso) identificada até o momento da predição (dia 137), pois nenhuma informação adicional sobre o processo de ganho de peso dos animais é considerada.

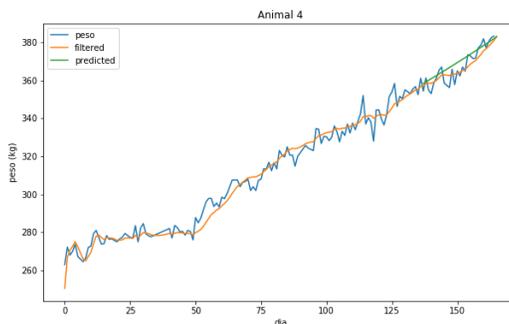


Figura 8. Dados observados (peso); predições após observar o dado mensurado do FKP (filtered); e predições baseadas apenas nos parâmetros estimados para o polinômio de grau 2 (predicted) para o Animal 4.

A Figura 9 ilustra um caso (animal 25) em que houve uma mudança na tendência de ganho de peso aproximadamente no mesmo momento em que foi realizada a predição, resultando em um erro de predição relativamente grande, 14.04 kg.

Em ambos os casos, observa-se ainda que a predição de peso fornecida pelo FKP se aproxima das medidas observadas em poucas iterações e passa a apresentar valores com variações menos abruptas (filtradas) que as apresentadas pelas medidas observadas.

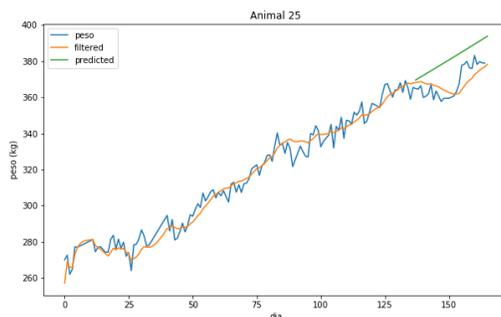


Figura 9. Dados observados (peso); predições após observar o dado mensurado do FKP (filtered); e predições baseadas apenas nos parâmetros estimados para o polinômio de grau 2 (predicted) para o Animal 25.

Redes Neurais

De modo geral, observou-se que as previsões mais precisas foram obtidas usando regressão linear com o conjunto de dados d , p_4 , p_3 , p_2 , p_1 , p como mostrado na Tabela 1 com os resultados individuais por animal e na Tabela 2 com as médias dos resultados individuais.

Tabela 1. Erro quadrático médio (rmsd) e coeficiente de correlação (r) dos métodos regressão linear (Reg. linear) e MLP.

	peso anterior		idade, peso anterior		4 pesos anteriores		idade, 4 pesos anteriores	
	rmsd	r	rmsd	r	rmsd	r	rmsd	r
animal 982126051792534								
Reg. linear	4.2625	0.9922	4.0306	0.9915	4.4321	0.991	4.1668	0.9924
MLP	5.0499	0.99	4.4721	0.9911	5.2257	0.9909	5.2582	0.9927
982126051793016								
Reg. linear	3.8272	0.9947	4.2904	0.9933	3.6101	0.9951	4.1555	0.9938
MLP	4.6423	0.9944	6.2586	0.9925	4.1911	0.9954	5.1791	0.9937

Continua

animal 982126051793055								
Reg. linear	4.8989	0.9922	3.8374	0.9955	4.4134	0.9935	3.6336	0.9959
MLP	5.4398	0.9916	4.0784	0.9947	5.7714	0.9938	3.8637	0.9954
animal 982126051793076								
Reg. linear	4.2964	0.987	2.6883	0.9955	4.1106	0.9881	2.6883	0.9955
MLP	4.5263	0.9865	4.758	0.9937	3.863	0.99	4.5297	0.9948
animal 982126051793080								
Reg. linear	5.1703	6.0701	3.7923	0.9931	5.0308	0.9837	3.7644	0.9927
MLP	6.0701	0.9806	4.6872	0.9916	6.0543	0.9816	5.5277	0.9917
animal 982126051793085								
Reg. linear	4.9248	0.9929	4.463	0.9942	4.7214	0.9936	4.3265	0.9945
MLP	4.727	0.9933	4.8659	0.9935	4.7954	0.9935	4.6797	0.9942
animal 982126051793097								
Reg. linear	3.5568	0.9957	3.9201	0.9942	3.2173	0.9963	4.1622	0.9932
MLP	4.2946	0.9941	4.0979	0.9936	4.6178	0.9919	5.0782	0.99
animal 982126051793110								
Reg. linear	5.0458	0.9881	3.557	0.9896	4.3155	0.9913	4.4424	0.9904
MLP	6.3956	0.982	5.4719	0.9856	5.3661	0.9869	5.1161	0.9878
animal 982126051793116								
Reg. linear	46.867	-0.1933	46.25	-0.2145	16.077	0.9388	10.269	0.9547
MLP	49.004	-0.0594	55.869	-0.1318	17.849	0.9251	16.203	0.9364
animal 982126051793117								
Reg. linear	39.926	-0.1803	39.987	-0.2239	10.943	0.9614	9.9848	0.9672
MLP	41.210	-0.034	47.186	-0.1772	13.796	0.9421	10.580	0.9636
animal 982126051793131								
Reg. linear	38.171	-0.233	38.037	-0.3138	11.8163	0.9502	10.264	0.962
MLP	40.6118	0.0153	44.367	-0.0613	11.5293	0.9529	11.1132	0.9601

Continua

animal 982126051793159								
Reg. linear	39.770	-0.1907	39.227	-0.2269	9.9807	0.9677	8.5148	0.9759
MLP	40.746	-0.0126	46.574	-0.1722	11.0136	0.9648	9.7524	0.9687
animal 982126051794374								
Reg. linear	34.77	-0.1727	34.292	-0.2352	15.062	0.9006	13.164	0.9224
MLP	35.844	-0.0337	38.220	-0.1194	14.363	0.9155	13.4	0.9196
animal 982126051794436								
Reg. linear	34.234	-0.1848	34.008	-0.2334	13.177	0.9318	10.443	0.9511
MLP	35.281	-0.0237	39.246	-0.1042	12.174	0.9341	10.486	0.9508
animal 982126051794443								
Reg. linear	34.467	-0.1955	34.286	-0.3281	4.4401	0.9916	4.3363	0.9918
MLP	35.444	-0.0326	40.735	-0.2710	14.951	0.9094	4.9982	0.9892
animal 982126051794446								
Reg. linear	5.1998	0.9905	4.8897	0.9914	4.6881	0.9923	4.8137	0.9916
MLP	7.7293	0.9826	6.2822	0.9857	6.3818	0.9872	5.8826	0.9875
animal 982126051794457								
Reg. linear	5.4581	0.9705	5.1403	0.9917	4.9374	0.9926	4.8872	0.9925
MLP	8.1638	0.9634	6.4905	0.987	5.7955	0.99	5.3771	0.991
animal 982126051794459								
Reg. linear	5.1575	0.9894	4.9698	0.9898	4.8347	0.9907	5.0235	0.9896
MLP	6.3631	0.9841	5.5144	0.9876	6.0027	0.9859	5.0279	0.9896
animal 982126051794486								
Reg. linear	33.703	0.1072	33.827	0.0958	33.827	0.0958		
MLP	34.068	0.0419	34.386	0.0512	11.3771	0.0512		
animal 982126051794490								
Reg. linear	6.6312	0.9907	5.9448	0.9926			2.8857	0.9944
MLP	8.22	0.986	6.6057	0.9915			6.4601	0.991

Continua

animal 982126051794496								
Reg. linear	30.935	0.4814	31.139	0.4705				
MLP	31.385	0.4608	31.914	0.4312				
animal 982126051794528								
Reg. linear	5.4111	0.9925	4.9292	0.9938	5.0565	5.8711	4.8599	0.9938
MLP	5.9481	0.9913	4.9001	0.9947	5.8711	0.991	5.2358	0.9928
animal 982126051794544								
Reg. linear	5.3737	0.9881	5.0603	0.9895	5.0789	0.989	5.0119	0.9893
MLP	6.8387	0.9808	5.9837	0.9854	5.5335	0.987	5.4706	5.0119
animal 982126051794548								
Reg. linear	5.6195	0.9914	5.3249	0.9922	5.4807	0.9916	5.2657	0.9922
MLP	7.027	0.9877	6.0074	0.9904	6.964	0.9874	5.935	0.9903
animal 982126051794560								
Reg. linear	2.5143	0.9959	2.6619	0.9954	2.8857	0.9944	2.9352	0.9942
MLP	2.8264	0.9948	2.6879	0.9953	3.4832	0.992	3.4123	0.9923

Tabela 2. Média do erro quadrático médio (rmsd) dos métodos regressão linear (Reg. linear) e MLP aplicados às séries temporais de ganho de peso dos animais.

	peso anterior	idade, peso anterior	4 pesos anteriores	idade, 4 pesos anteriores
Reg. linear	15,8961	15,5254	7,71039	5,7068
MLP	17,72	17,906	7,966	6,7637

Discussão

Dados

Os inúmeros casos de animais com padrões de pesagens análogos ao apresentado na Figura 4B é preocupante, pois a ocorrência de sequências longas de pesagens linearmente relacionadas acaba por introduzir vieses ao processo de desenvolvimento de modelos analíticos, objeto deste estudo. Posteriormente, verificou-se que essas ocorrências devem-se ao fato de a

empresa responsável pela balança realizar um tratamento dos dados antes de disponibilizá-los para uso. Assim, novos pontos são inseridos no conjunto por meio de métodos que exploram a interpolação de dados em situações em que não há registro de pontos válidos. Dessa maneira, sequências de pontos com crescimento linear são muito frequentes no conjunto de dados, o que não corresponde ao que ocorre no mundo real com os animais.

Em relação aos dados faltantes a partir de 12/01/2022, verificou-se posteriormente que esses animais foram retirados do experimento para recuperação da pastagem naquele local.

Curvas não lineares

As curvas resultantes dos ajustes com os dados obtidos da balança, apresentados na Figura 5, revelam características conflitantes com as situações esperadas de curva de crescimentos reais. Por exemplo, na curva *optimized brody* observa-se um valor para o peso de nascimento negativo.

Em relação à inserção dos pesos de nascimento e desmama, no conjunto de dados utilizado para o ajuste das curvas, observa-se uma melhora na forma da curva (Figuras 6 e 7), o que demonstra a grande relevância dos pesos nestes momentos da vida dos indivíduos. Contudo, também é possível observar que o peso à desmama fica geralmente bastante deslocado em relação ao traçado das curvas. Isso indica que nenhuma delas parece representar bem o crescimento dos animais desde seu nascimento até sua maturidade passando pela desmama. Um caminho que pode ser explorado é a modelagem do crescimento desses animais com a agregação de, pelo menos, duas funções e com especial atenção ao momento de desmama. Por exemplo, uma função representaria o crescimento dos animais até este momento e outra representaria o período da desmama até a maturidade. O ideal, no entanto, é que os dados de pesos pudessem ser coletados ao longo de toda a vida do animal para uma avaliação mais precisa de seu crescimento.

Filtros de Kalman

A utilização de FKP resultou em uma estimativa de erro de predição para o peso dos animais no dia 165 (29 dias à frente do dia da predição) muito

próxima de zero (-1.48 kg), com um desvio padrão relativamente pequeno (10.27 kg).

Embora existam pontos para melhoria, como a estimativa de alguns dos parâmetros do FKP que foram de forma ad hoc, é preciso ressaltar que abordagem limita a aplicação a uma vizinhança da curva de ganho de peso aproximada como um polinômio de grau 2. Isso significa que há um limite para o número de dias à frente para realização de uma predição minimamente acurada, embora esse limite possa variar de acordo com o comportamento da curva de ganho de peso.

Outra limitação da abordagem é a dificuldade de acompanhar mudanças abruptas na curva de ganho de peso, que resultam em maiores erros de predição (Figura 9), embora, neste caso, pese a dúvida sobre a qualidade dos dados.

Além disso, admitindo-se um número k de dias à frente em que uma predição confiável é possível utilizando FKP, a utilização dessa abordagem para o problema proposto implica limitar a questão a se a data objetivo encontra-se entre a data corrente e k dias à frente.

Redes Neurais

Há duas hipóteses para explicar o melhor desempenho observado para a regressão linear em relação à rede neural MLP. A primeira hipótese é que o período da pesagem não é longo e nesta fase o ganho de peso realmente teve comportamento linear. Por exemplo, ao observar a curva de crescimento do animal com melhor regressão linear para o conjunto de dados `d,p4,p3,p2,p1,p`, `982126051793076`, verifica-se a ocorrência de um longo período sem pesagens, preenchida pelo software, associado à balança por uma reta, o que pode ter sido determinante para que esse intervalo contendo uma grande quantidade de pontos dominasse a calibração do regressor linear (Figura 10).

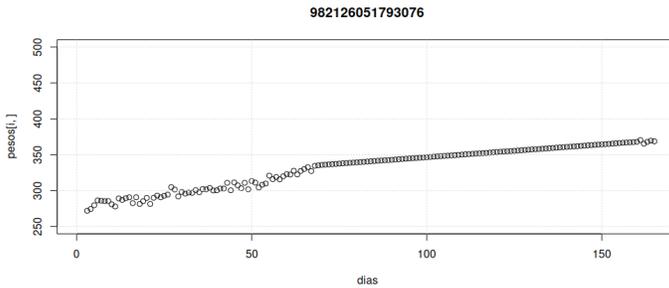


Figura 10. Retificação da curva de ganho de peso causada pelo algoritmo de imputação de dados da balança.

A outra hipótese é que o preenchimento de pesos faltantes de forma linear tenha contribuído para a retificação da curva de crescimento. Assim, quando observamos a curva de crescimento do animal com pior regressão linear para o conjunto de dados d,p4,p3,p2,p1,p, 982126051794374, verifica-se um cenário mais próximo àquele esperado, ou seja, uma frequência muito maior de registros de pesagens reais em contraponto a pesagens preenchidas pelo software associado à balança (Figura 11).

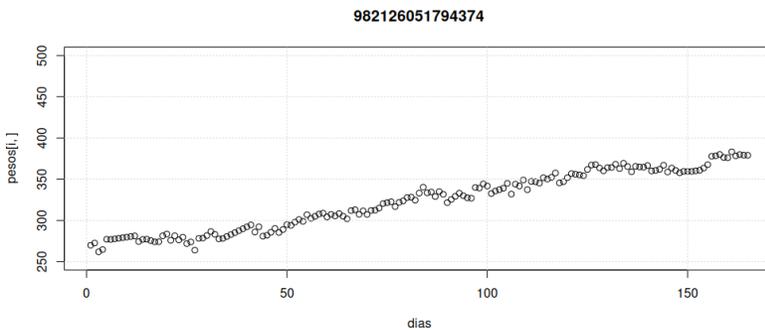


Figura 11. Curva de crescimento com mais pesagens reais distribuídas no período considerado.

Conclusão

Os dados utilizados neste experimento ainda são insuficientes para a determinação de um modelo de crescimento confiável que envolva desde o nascimento dos animais até sua maturidade. Os dados cobrem apenas um período de vida dos animais e não envolvem o período de nascimento até meses após a desmama e nem o momento em que seu crescimento atinge um platô. É fundamental ampliar o período de coleta dos dados.

Os dados fornecidos pela balança de pesagem não são confiáveis nos pontos em que dados foram preenchidos por algoritmos criados pela empresa que comercializa o modelo utilizado no experimento. Alguma forma de tratamento é desejável para que haja apenas um peso para cada dia e cada animal considerado, mas não é desejável o cálculo, a partir de pesos obtidos em outros dias, de uma pesagem em dia que não apresenta registros. É melhor haver falta de dados do que dados inconsistentes. Assim, a própria equipe responsável pelo desenvolvimento dos modelos de crescimento poderia tratar esses dados faltantes. Com isso, foram geradas novas demandas para que a API que fornece os pesos diários dos animais não insira dados para preencher essas lacunas ou que indique quais foram os pontos inseridos e que forneça todas as pesagens realizadas para cada animal ao longo do dia, e não apenas um peso consolidado.

Em relação às funções não lineares, nenhuma se ajusta muito bem aos pesos obtidos no experimento, embora sejam utilizadas com grande frequência na literatura técnico-científica para representar o crescimento de bovinos. Com a disponibilidade de maior quantidade de dados será possível trabalhar em modelos mais representativos do crescimento animal, inclusive considerando a possibilidade de explorar diferentes curvas para cada fase do animal.

Ainda assim, desde que consideradas essas limitações de representatividade, a curva Brody ajustada aos pesos ao nascimento, à desmama e aos coletados pela balança representa bem o crescimento dos bovinos.

Em relação à abordagem baseada em Filtros de Kalman, a partir dos resultados experimentais e limitando-se a uma vizinhança de k dias à frente em que a predição é confiável, pode-se considerar a abordagem proposta como

promissora. As limitações quanto à quantidade e qualidade dos dados, contudo, indicam a necessidade de novos estudos com novos conjuntos de dados.

Em relação à abordagem baseada em redes neurais multicamadas, a falta de um conjunto de séries temporais de maior duração da pesagem não permite avaliar claramente a adequação da metodologia ao problema. Para os dados disponíveis, no momento, o método regressão linear apresentou melhor desempenho do que as redes neurais.

Referências

- BRODY, S. **Bioenergetics and growth; with special reference to the energetic efficiency complex in domestic animals.** Oxford: Reinhold, 1945.
- BROWN, R. G.; HWANG, P. Y. C. **Introduction to random signals and applied Kalman filters:** with MATLAB exercises. 4. ed. New York: John Wiley & Sons, 2012.
- CEZAR, I. M.; QUEIROZ, H. P.; THIAGO, L. R. L. de S.; CASSALES F. L. G.; COSTA, F. P. **Sistemas de produção de gado de corte no Brasil:** uma descrição com ênfase no regime alimentar e no abate. Campo Grande, MS: Embrapa, 2005. 40 p. (Embrapa Gado de Corte. Documentos, 151). Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/326307>. Acesso em: 17 out. 2022.
- COIMMA. **BalPass.** Disponível em: <https://coimma.com.br/balpass>. Acesso em: 17 ago. 2022.
- DOJOT. Disponível em: <https://dojot.com.br>. Acesso em: 17 ago. 2022.
- GOMPERTZ, B. On the nature of the function expressive of the law of human mortality, and on a new mode of determining the value of life contingencies. **Philosophical Transactions of the Royal Society of London**, v. 115, p. 513–583, 1825. DOI: [10.1098/rstl.1825.0026](https://doi.org/10.1098/rstl.1825.0026).
- GOOGLE. **Google maps.** Disponível em: <https://www.google.com/maps/@-20.4139528,-54.7099036,1048m/data=!3m1!1e3>. Acesso em: 27 out. 2022.
- HERRMANN, P.; RODRIGUES, R. DE A. R. Rede ILPF association actions. In: WORLD CONGRESS ON INTEGRATED CROP-LIVESTOCK-FORESTRY SYSTEMS, 2., 2021. **WCCLF 2021 proceedings.** Brasília, DF: Embrapa, 2021. p. 930-932. WCCLF 2021. Evento online. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/231054/1/Rede-ILPF-association-actions-2021.pdf>. Acesso em: 17 out. 2022.
- LANDI, A.; PIAGGI, P.; LAURINO, M.; DEMICUCCI, D. Artificial Neural Networks for nonlinear regression and classification. In: INTERNATIONAL CONFERENCE ON INTELLIGENT SYSTEMS DESIGN AND APPLICATIONS, 10., 2010, Cairo. **Proceedings...** [Piscataway]: IEEE, 2010. p. 115-120. DOI: [10.1109/ISDA.2010.5687280](https://doi.org/10.1109/ISDA.2010.5687280).
- LOPES, F. B.; MAGNABOSCO, C. de U.; SOUZA, F. M. de; ASSIS, A. S. de; BRUNES, L. C. Análises de dados longitudinais em bovinos nelore mocho por meio de modelos não lineares. **Archivos de Zootecnia**, v. 65, n. 250, p. 123-129, 2016.
- PROJETO PlattAgro. Disponível em: <https://www.cpqd.com.br/inovacao/platiagro>. Acesso em: 17 ago. 2022.
- RICHARDS, J. F. A flexible growth function for empirical use. **Journal of Experimental Botany**, v. 10, n. 2, p. 290-301, June 1959. DOI: [10.1093/jxb/10.2.290](https://doi.org/10.1093/jxb/10.2.290).
- RODRIGUES FILHO, J. R.; SANTOS NETO, Q. I. dos. Software de gerenciamento para pesagem automatizada de bovinos da Embrapa Gado de Corte utilizando a balança de passagem Coimma/Embrapa. In: JORNADA CIENTÍFICA EMBRAPA GADO DE CORTE, 9., 2013, Campo Grande, MS. **[Anais...]**. Campo Grande, MS: Embrapa Gado de Corte, 2013. (Embrapa Gado de Corte. Documentos, 204). Comissão organizadora: Denise Baptagliin Montagner, Grácia Maria Soares Rosinha, Rodrigo Carvalho Alva. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/handle/doc/971473>. Acesso em: 17 out. 2022.

SILVA, F. F. e; AQUINO, L. H. de; OLIVEIRA, A. I. G. Influência de fatores genéticos e ambientais sobre as estimativas dos parâmetros das funções de crescimento em gado nelore. **Ciência e Agrotecnologia**, v. 25, n. 5, p. 1195-120555, 2001.

SISTEMA automático de pesagem ajuda a monitorar rebanho. **Dia de Campo na TV**. Brasília, DF: Embrapa; Campo Grande, MS: Embrapa Gado de Corte, 2019. Programa de TV.

SPERANZA, E. A.; HIGA, R. H.; VISOLI, M. C.; MARTINS, C.; CARROMEU, C. Plataforma de internet das coisas para monitoramento de produtividade e bem-estar animal em sistemas de integração lavoura-pecuária-floresta. In: CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO, 2022, Campinas. **Anais...** Campinas: Associação Brasileira de Agricultura de Precisão, 2022. p. 378-385. Edição Técnica: Leandro Maria Gimenez, Christian Bredemeier. ConBAP 2022.

SVERSUTTI, P. E.; YADA, M. M. Criação extensiva de bovinos de corte. **SIMTEC**: Simpósio de Tecnologia da Fatec Taquaritinga, v. 5, n. 1, p. 382-391, 2018.

VAZ, G. J.; APOLINÁRIO, D. R. de F.; CORREA, J. L.; VACARI, I.; GONZALES, L. E.; DRUCKER, D. P.; BARIANI, J. M.; EVANGELISTA, S. R. M.; ROMANI, L. A. S. AgroAPI: criação de valor para a Agricultura Digital por meio de APIs. In: CONGRESSO BRASILEIRO DE AGROINFORMÁTICA, 11., 2017, Campinas. **Ciência de dados na era da agricultura digital**: anais. Campinas: Editora da Unicamp: Embrapa Informática Agropecuária, 2017. p. 59-68. SBIAgro 2017. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/handle/doc/1083275>. Acesso em: 17 out. 2022.

VERHULST, P. F. Recherches mathématiques sur la loi d'accroissement de la population. **Nouveaux Memoires de l'academie Royale des Sciences**, v. 18, p. 1-41, 1845.

VON BERTALANFFY, L. Quantitative laws in metabolism and growth. **Quarterly Reviews of Biology**, v. 32, n. 3, p. 217-231, Sept. 1957. DOI: [10.1086/401873](https://doi.org/10.1086/401873).

WITTEN, I. H.; FRANK, E.; HALL, M. A. **Data mining**: practical machine learning tools and techniques. 3. ed. Amsterdam: Morgan Kaufmann, 2011.

ZARCHAN, P.; MUSSOFF, H. **Fundamentals of Kalman filtering**: a practical approach. 2. ed. Reston: American Institute of Aeronautics and Astronautics, 2005. (Progress in astronautics and aeronautics, v. 208).



Agricultura Digital