



Programa de Pós-Graduação em Zootecnia

**USO DE REDES NEURAIS PARA PREDIÇÃO DO
CONSUMO E DESEMPENHO DE NOVILHAS
LEITEIRAS NO SEMIÁRIDO**

Larissa Inácio Soares de Oliveira

2023

LARISSA INÁCIO SOARES DE OLIVEIRA

**USO DE REDES NEURAIS PARA PREDIÇÃO DO CONSUMO E DESEMPENHO DE NOVILHAS
LEITEIRAS NO SEMIÁRIDO**

Dissertação apresentada à Universidade Estadual de Montes Claros como parte das exigências do Programa de Pós-Graduação em Zootecnia, área de concentração em Zootecnia no Semiárido, para obtenção do título de Mestre.

Orientadora

Prof.^a Dr.^a Maria Dulcinéia da Costa

Janaúba

2023

Ficha Catalográfica

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

Oliveira, Larissa Inácio Soares de

O48u Uso de redes neurais para predição do consumo e desempenho de novilhas leiteiras no semiárido [manuscrito] / Larissa Inácio Soares de Oliveira. – 2023.
53 p.

Dissertação (Mestrado) – Programa de Pós-Graduação em Zootecnia, Universidade Estadual de Montes Claros – Janaúba, 2023.

Orientadora: Prof^a. D. Sc. Maria Dulcinéia da Costa.

1. Bovinos de leite. 2. Novilhos. 3. Redes Neurais (Neurobiologia). I. Costa, Maria Dulcinéia da. II. Universidade Estadual de Montes Claros. III. Título.

CDD. 636.2142

Catálogo: Joyce Aparecida Rodrigues de Castro Bibliotecária CRB6/2445

Declaração - UNIMONTES/PRPG/PPGZ - 2023

Montes Claros, 12 de setembro de 2023.

LARISSA INÁCIO SOARES DE OLIVEIRA

USO DE REDES NEURAIIS PARA PREDIÇÃO DO CONSUMO E DESEMPENHO DE NOVILHAS LEITEIRAS NO SEMIÁRIDO

Dissertação apresentada à Universidade Estadual de Montes Claros como parte das exigências do Programa de Pós-Graduação em Zootecnia, área de concentração em Zootecnia no Semiárido, para obtenção do título de Mestre em Zootecnia.

APROVADA em 29 de agosto de 2023.

Dra. Maria Dulcinéia da Costa/Presidente/UNIMONTES

Dr. Vicente Ribeiro Rocha Júnior/ Membro Interno/ UNIMONTES

Dr. Flávio Pinto Monção/ Membro Interno/ UNIMONTES

Dr. Marcos Flávio Silveira Vasconcelos D'Angelo/ Membro Interno/ UNIMONTES

Dr. Antônio Eustáquio Filho/Membro Externo/IFNMG-SALINAS

JANAÚBA, MINAS GERAIS – BRASIL/2023



Documento assinado eletronicamente por **Vicente Ribeiro Rocha Junior**, **Professor(a)**, em 12/09/2023, às 13:44, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 47.222, de 26 de julho de 2017](#).



Documento assinado eletronicamente por **Antônio Eustáquio Filho**, **Usuário Externo**, em 05/11/2023, às 19:49, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 47.222, de 26 de julho de 2017](#).



Documento assinado eletronicamente por **Flávio Pinto Monção, Professor(a)**, em 06/11/2023, às 11:01, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 47.222, de 26 de julho de 2017](#).



Documento assinado eletronicamente por **Marcos Flavio Silveira Vasconcelos Dange, Professor de Educação Superior**, em 08/11/2023, às 19:30, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 47.222, de 26 de julho de 2017](#).



Documento assinado eletronicamente por **Maria Dulcineia da Costa, Professora de Educação Superior**, em 09/11/2023, às 10:08, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 47.222, de 26 de julho de 2017](#).



A autenticidade deste documento pode ser conferida no site http://sei.mg.gov.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **73129818** e o código CRC **637C212F**.

SUMÁRIO

NORMAS DA REVISTA CIENTÍFICA	6
RESUMO GERAL.....	7
GENERAL ABSTRACT	8
1 INTRODUÇÃO GERAL.....	9
2 REVISÃO DE LITERATURA	10
2.1 Redes neurais.....	10
2.2 Caracterização do sistema produtivo no semiárido	12
2.3 Consumo de alimentos	15
2.4 Modelos de predição de consumo de matéria seca.....	19
2.5 Desempenho animal	21
2.6 Modelos de predição de desempenho	24
REFERÊNCIAS	27
CAPÍTULO 1: 4. Uso de Redes Neurais para predição do consumo e desempenho de novilhas leiteiras.....	31
4.1 Introdução	32
4.2 Material e métodos	33
4.2.1 Declaração de ética.....	33
4.2.2 Local do experimento	33
4.2.3 Manejo geral dos animais e dietas	33
4.2.4 Obtenção das culturas	34
4.3 Resultados	38
4.4 Discussão	45
4.5 Conclusão.....	49
4.7 Referências bibliográficas.....	50
CONSIDERAÇÕES FINAIS	52

NORMAS DA REVISTA CIENTÍFICA

Esta dissertação segue as premissas básicas da Revista Computers and Electronics in Agriculture, exceto a localização das tabelas e idioma. Link: <https://www.elsevier.com/journals/computers-and-electronics-in-agriculture/0168-1699/guide-for-authors>

RESUMO GERAL

OLIVEIRA, Larissa Inácio Soares. **Uso de redes neurais para predição do consumo e desempenho de novilhas leiteiras no semiárido**. 2023. 53 p. Dissertação (Mestrado em Zootecnia) - Universidade Estadual de Montes Claros, Janaúba, Minas Gerais, Brasil.¹

Selecionar as melhores novilhas de reposição em um rebanho leiteiro é fundamental para melhorar a produtividade e reduzir custos. Uma novilha eficiente apresenta elevadas taxas de crescimento e atinge idade precoce a primeira inseminação e parto. Para acompanhar esse desenvolvimento, é necessário conhecer as medições corporais e usá-las nas predições de peso futuro, além de prever corretamente o consumo voluntário de alimentos. Várias metodologias são utilizadas para fazer predições e, dentre elas, as redes neurais surgem como alternativa aos modelos estatísticos tradicionais. Diante disso, o objetivo desta pesquisa foi realizar uma predição de consumo e desenvolvimento ponderal de novilhas mestiças leiteiras criadas no semiárido, através do método de redes neurais. Foi desenvolvido um banco de dados a partir de dissertações produzidas na UNIMONTES, com variáveis de entrada para construção da rede neural relacionadas ao consumo e digestibilidade de nutrientes, síntese de proteína microbiana, comportamento ingestivo e desenvolvimento ponderal. As variáveis de saída foram consumo de matéria seca e ganho de peso médio diário. Foram utilizados 70% dos dados para o treinamento da rede e 30% para sua validação. Os procedimentos foram efetuados por meio da Neural Network Toolbox do Matlab® 6.5. Foram realizados dois experimentos, em que o Experimento 1 previu o ganho de peso médio diário e o Experimento 2 fez a predição do consumo de matéria seca. A rede neural foi eficiente nas predições, tanto pela semelhança com o consumo voluntário e ganho de peso real, quanto pelo baixo erro médio quadrático. O consumo de matéria seca real foi 8,33 kg/dia, enquanto a rede neural previu consumo de 8,34 kg/dia. Já o ganho de peso real foi de 0,93 kg/dia, enquanto o predito foi 0,98 kg/dia. Ao comparar os valores reais de consumo de matéria seca com algumas equações publicadas na literatura, observou-se sub e superestimação do consumo.

Palavras-chave: Consumo de alimentos, Desempenho animal, Novilhas mestiças, Predições

¹ Comitê de Orientação: Prof.^a Maria Dulcinéia da Costa - Departamento de Ciências Agrárias/ UNIMONTES (Orientadora); Vicente Ribeiro Rocha Júnior; Flavio Pinto Monção - Departamento de Ciências Agrárias/UNIMONTES (Coorientador).

GENERAL ABSTRACT

OLIVEIRA, Larissa Inácio Soares. **Use of neural networks to predict the consumption and performance of dairy heifers in the semi-arid region.** 2023. 53 p. Dissertation (Master's degree in Animal Science) – State University of Montes Claros, Janaúba, Minas Gerais, Brasil.²

Selecting best replacement heifers in dairy herd is fundamental to improve productivity and to reduce costs. An efficient heifer has high growth rates and reaches early age for first insemination and calving. In order to monitor this development, it is necessary to know body measurements and use them to predict future weight, as well correctly predicting food consumption. Various methodologies are used to make predictions and among them, neural networks have emerged an alternative to traditional statistical models. This study aimed to predict consumption and growth of crossbreed dairy heifers raised in semi-arid conditions by means of neural networks. A set data from dissertations carried out at UNIMONTES was used, with input variables to building neural network related nutrient intake and digestibility, microbial protein synthesis, ingestive behavior and growth. The output variables were dry matter intake and average daily weight gain. They were used 70% from data to training network and 30% for its validation. The procedures were carried out using Neural Network Toolbox in Matlab® 6.5. Two experiments were carried out: Experiment 1 predicted average daily weight gain and Experiment 2 predicted dry matter intake. The neural network was efficient in predictions, as well because similarity in voluntary intake and weight gain real as because low mean square error. The actual dry matter intake was 8.33kg/day, while the neural network predicted intake of 8.34kg/day, and actual weight gain was 0.93kg/day, while predicted weight gain was 0.98kg/day. When comparing actual dry matter intake values with some equations published in literature, under- and overestimation of intake was observed.

Keywords: Feed intake, Animal performance, Crossbreed heifers, Predictions

² Guidance Committee: Prof. Maria Dulcinéia da Costa - Department of Agrarian Sciences/ UNIMONTES (Advisor); Vicente Ribeiro Rocha Júnior, Flávio Pinto Monção – Department of Agrarian Sciences/UNIMONTES (Co-advisor).

1 INTRODUÇÃO GERAL

A fase de recria de fêmeas leiteiras compreende o período desde o desmame até a puberdade (Barros et al., 2017), sendo a etapa mais importante no sistema de produção de leite, considerando que está relacionada diretamente com os aspectos produtivos da vaca quando adulta. Nessa fase, é importante propiciar bom desempenho das novilhas, principalmente com relação às boas taxas de ganho de peso para não elevar a idade ao primeiro parto (NRC, 2001).

A estratégia nutricional adotada nos sistemas de produção leiteira muitas vezes não possibilita às novilhas atingirem peso adequado à puberdade, aproximadamente 55 a 60% do peso corporal maduro (PCM) na inseminação (Van Amburgh et al., 2019). Como consequência, há aumento no custo de criação dessas fêmeas leiteiras, que é a segunda maior fonte de despesas no sistema de produção de leite (Mendes Neto et al., 2007).

O consumo de matéria seca (CMS) é um dos mais importantes indicadores de saúde animal e desempenho do gado leiteiro (Bareille et al., 2003), sendo que essa ingestão é regulada por diversos fatores que atuam direta ou indiretamente sobre os animais, tais como peso corporal, produção e composição do leite, estado fisiológico, condições ambientais, entre outros fatores característicos do próprio alimento (NRC, 2001). Portanto, o consumo de alimentos torna-se o principal fator limitante no suprimento das exigências nutricionais, e pode prejudicar a produtividade e comprometer a lucratividade da atividade pecuária (Azevêdo et al., 2010).

Vários modelos para predição do consumo de matéria seca (CMS) têm sido desenvolvidos e utilizados, nos quais as características dos animais e a composição da dieta são frequentemente usados como variáveis (Busanello et al., 2021). Para novilhas leiteiras, esses modelos têm sido usados para calcular os nutrientes fornecidos pela dieta ou para prever as necessidades de nutrientes para manutenção, crescimento e gestação, e para criar curvas de crescimento para diferentes raças. Dessa forma, a predição correta é essencial para otimizar o uso de nutrientes e o desempenho produtivo dos animais (Souza et al., 2014). Nesse campo de predições, as Redes Neurais Artificiais (RNA's), que fazem parte da área conhecida como Inteligência Computacional, tornam-se alternativa aos métodos estatísticos tradicionais, sendo inspirados no sistema nervoso dos seres vivos e constituídos por neurônios artificiais (Haykin, 2009; Silva et al., 2017).

Diante disso, objetiva-se por meio deste trabalho realizar uma meta-análise para predição do consumo e desenvolvimento ponderal de novilhas mestiças leiteiras em condições de semiárido, com a utilização das redes neurais artificiais.

2 REVISÃO DE LITERATURA

2.1 Redes neurais

As redes neurais artificiais são modelos computacionais inspirados na estrutura do sistema nervoso dos seres vivos e fazem parte da área conhecida como Inteligência Artificial. Elas têm a capacidade de adquirir e manter conhecimento e podem ser definidos como conjunto de unidades de processamento representadas por neurônios artificiais (Silva et al., 2017). A computação neural constitui uma alternativa à computação algorítmica convencional por não ser baseada em regras ou programas (Braga et al., 2000).

O trabalho em redes neurais artificiais foi motivado pelo reconhecimento de que o cérebro humano computa de maneira totalmente diferente do computador digital convencional (Haykin, 2009). O procedimento da solução de problemas passa inicialmente pela fase de aprendizagem, em que um conjunto de exemplos é apresentado para a rede que extrai as características necessárias e gera respostas. Depois de concluído o processo de aprendizagem, a rede pode generalizar o conhecimento adquirido, possibilitando a estimativa de soluções até então desconhecidas (Braga et al., 2000; Silva et al., 2017).

A capacidade de aprender através de exemplos e de generalizar a informação aprendida é o atrativo principal do modelo de redes neurais. A generalização está associada à capacidade da rede de aprender através de exemplos e, posteriormente, dar respostas coerentes para dados não conhecidos. Isso demonstra a capacidade de extrair informações não apresentadas de forma explícita através dos exemplos. Tudo isso faz das redes neurais uma ferramenta computacional extremamente poderosa e atrativa para a solução de problemas complexos (Braga et al., 2000; Silva et al., 2017).

De acordo com Silva et al. (2017), a primeira publicação relacionada à neurocomputação foi em 1943, quando McCulloch e Pitts criaram o primeiro modelo matemático inspirado em neurônios biológicos. Muitos outros pesquisadores continuaram o desenvolvimento de modelos matemáticos baseados no neurônio biológico, gerando muitos

algoritmos de aprendizado. Entre os diversos trabalhos que surgiram, destaca-se o de Frank Rosenblatt, que elaborou o modelo básico do Perceptron, em 1958, e de Widrow e Hoff, que desenvolveram, em 1960, uma rede chamada MADALINE (ADALINE Múltipla).

No entanto, em 1969, a neurocomputação sofreu uma reviravolta com a publicação de um livro que discutia enfaticamente as limitações das redes neurais da época – que eram compostas por uma única camada, como o Perceptron e o ADALINE. O livro demonstrou a impossibilidade de as redes neurais classificarem padrões de classes não linearmente separáveis. Após o impacto dessa publicação, as pesquisas sobre redes neurais foram bastante reduzidas, e em 1982, com a rede recorrente baseada em funções de energia proposta por Hopfield, o prestígio original de antes da publicação do livro foi recuperado. Após o final da década de 80, apoiados por esse trabalho, os cientistas retomaram o interesse pela área (Silva et al., 2017).

O retorno definitivo das redes neurais artificiais deve-se ao desenvolvimento de computadores com capacidades de processamento e memória melhores, a criação de algoritmos de otimização mais eficientes e as novas descobertas sobre o sistema nervoso biológico. Nos últimos anos, dezenas de novas e diferentes pesquisas possibilitaram avanços teóricos em redes neurais artificiais (Silva et al., 2017). Conforme esses autores, as capacidades das redes neurais artificiais possibilitam a solução de vários tipos de problemas de diversas áreas do conhecimento, como medicina, química, biologia, etiologia, indústria alimentícia, área farmacêutica, financeira e econômica. Na ciência animal, ainda são poucos os trabalhos que utilizam a inteligência computacional, porém, essa é uma ferramenta interessante e que, certamente, será bastante utilizada nos próximos anos nessa área.

Cavero et al. (2008) desenvolveram e testaram um modelo de detecção de mastite com a aplicação das redes neurais usando dados de produção de leite, fluxo de leite, dias em leite e condutividade elétrica. No estudo, eles utilizaram a rede Feedforward e observaram especificidade variando entre 51,1% e 74,9%, enquanto a taxa de erro ficou entre 51,3% e 80,5%. Com base nesses resultados, o modelo forneceu alto número de falsos alarmes, o que implicou a baixa especificidade para aplicação prática. Portanto, o desempenho não foi satisfatório, provavelmente devido à insuficiência de informações de entrada relacionadas à mastite. Informações adicionais relacionadas à mastite provavelmente melhorariam o desempenho do modelo.

Meckbach et al. (2021) testaram a capacidade de uma rede neural profunda (convolucional – CNN) na determinação do peso vivo de suínos através de imagens de profundidade e seus pesos, com uma base de dados de mais de 400 animais registrados em quatro momentos durante a engorda. Ao treinar e testar o conjunto de dados, foram obtidos coeficiente de determinação $> 0,97$ e erro percentual médio de cerca de 4%. Esses resultados mostram que a rede neural é capaz de extrair as características mais importantes para a estimativa de peso por conta própria e fornecer previsão de peso precisa em diferentes fases da vida.

Taylor et al. (2022) desenvolveram modelos de aprendizado a partir de uma rede neural recorrente de memória de longo prazo (LSTM), utilizando dados de peso vivo, consumo alimentar, temperatura ambiental e sazonalidade para prever o tempo necessário para suínos em crescimento atingirem peso final de 90 kg, como alternativa para prever diretamente o peso vivo futuro. No geral, a rede neural obteve o melhor desempenho de previsão, com erro médio padrão de 2,470 dias e coeficiente de correlação de 0,962. A integração de dados de temperatura ambiental e sazonalidade nos modelos resultou em melhoria no desempenho preditivo. Os resultados demonstraram o potencial desse modelo como ferramenta da pecuária de precisão para a previsão precoce de crescimento em suínos de terminação comercial.

2.2 Caracterização do sistema produtivo no semiárido

A rede de produção leiteira no Brasil apresenta sistemas de produção heterogêneos, possuindo bacias leiteiras tradicionais que contam com produção especializada em Minas Gerais, Rio Grande do Sul e Santa Catarina, assim como vários pequenos produtores de leite espalhados por todo o país. Em Minas Gerais, a produção leiteira tem passado por diversas transformações e representa uma atividade econômica fundamental para o estado, já que é o maior produtor do Brasil, com produtividade de 9,6 bilhões, 27,2% na produção total do país, de aproximadamente 35,3 bilhões de litros em 2021, demonstrando estabilidade em comparação com a produção estadual em 2020 (IBGE, 2021).

Entretanto, algumas regiões do estado possuem uma menor eficiência e tradição para este tipo de produção, como é o caso da região Norte, que representou cerca de 3,3% da produção total do estado em 2021 e, juntamente com a região Noroeste e

Jequitinhonha/Mucuri, são as mesorregiões que apresentaram a menor contribuição para a produção de leite, totalizando 14,4% (IBGE, 2021). Apesar da baixa influência na produtividade, houve incremento de 36,4% na produção da mesorregião Norte entre os anos de 2017 e 2021, ampliando a produtividade de 229 para 313 milhões de litros de leite, aproximadamente. As microrregiões que apresentaram maior crescimento nesse período foram Janaúba (44,4%), Montes Claros (39,6%) e Januária (27,2%) (IBGE, 2021).

A produção de leite na mesorregião Norte de Minas Gerais possui a característica marcante da heterogeneidade, visto que facilmente são encontrados, em uma mesma microrregião, produtores especializados e pequenos produtores, onde essa atividade se torna complemento à agricultura ou à pecuária de corte. Outra característica importante é a predominância de propriedades pequenas e médias com características da agricultura familiar, com famílias vivendo exclusivamente com a renda dessa atividade (Azevedo et al., 2011; Santos, 2012; Menezes et al., 2014).

Diante disso, pode-se constatar a importância da pecuária nessa mesorregião, que está inserida no semiárido juntamente com os estados do Nordeste brasileiro. As características principais dessa região são a precipitação pluviométrica média anual abaixo de 800 mm; índice de aridez até 0,5; calculado pela relação entre as chuvas e a evapotranspiração, e, por fim, risco de seca maior que 60% (Pereira Júnior, 2007). O clima também é do tipo semiárido, com temperaturas altas, forte incidência solar, além de chuvas irregulares e escassas concentradas em um período restrito (Sá & Silva, 2010). Desse modo, a produção animal torna-se alternativa ou ainda complemento à agricultura, já que essa é dependente das precipitações e pode desencadear prejuízos. Além disso, essa atividade auxilia na produção de alimentos para as famílias, na geração de empregos e renda e intensifica a cadeia produtiva que participa ativamente da economia do estado (Santos et al., 2015).

Considerando que as características climáticas de todo o território brasileiro, não apenas das regiões semiáridas, são desfavoráveis para a criação de animais de origem europeia, o uso de animais zebuínos pode ser uma opção, porém, a utilização de cruzamentos é mais difundida no Brasil e tem como resultado os animais mestiços. Essa prática, na pecuária leiteira, é uma forma de complementariedade das raças e combina a maior produção de leite das raças taurinas (*Bos taurus taurus*) com a adaptação e tolerância às condições adversas das raças zebuínas (*Bos taurus indicus*) (Oliveira Júnior et al., 2017), particularidade marcante da região semiárida.

O animal Girolando é resultado do cruzamento entre gado Holandês (H) e Gir (G). No Brasil, a maior parte da produção de leite é fornecida por bovinos mestiços, que são responsáveis por 80% da produção total de leite, principalmente da raça Girolando, estando esta raça presente na maioria das fazendas leiteiras (Cole & Silva, 2016). Entre as principais características selecionadas para esta raça estão a maior produção e composição do leite, saúde do úbere, rusticidade, e suas principais características são tolerância ao estresse térmico e resistência a endo e ectoparasitas, sendo capazes de manter bom nível de produção em diferentes sistemas de manejo e de condições climáticas (Silvestre et al., 2021; Silva et al., 2022).

A composição genética do Girolando varia de 1/4HG a 7/8HG, porém, o foco maior dos cruzamentos busca a fixação do padrão racial na composição racial 5/8HG, sendo considerados como Puro Sintético (PS), ou seja, a raça propriamente dita. Atualmente, é a raça que mais cresce na produção de sêmen no Brasil, sendo que em 2021 apresentou aumento de mais de 9% de doses produzidas em relação ao ano anterior. Além disso, sua produtividade cresce a cada ano, passando de 3.695 kg de leite em 2000 para 6.032 kg em 2021, isso representa aumento de 60% em 20 anos (Silva et al., 2022).

Em relação às culturas relevantes e adaptadas ao clima quente e seco da região semiárida brasileira, que são utilizadas na alimentação animal, estão incluídas o capim-buffel (*Cenchrus ciliaris*) e a palma forrageira (*Opuntia cochenillifera*), sendo dois dos principais recursos forrageiros da região, destacando-se pela alta resistência à seca e elevada produção de biomassa, mesmo em condições de elevada temperatura e baixa precipitação (Santos et al., 2015). Outras alternativas são o capim-elefante-BRS-capiaçu (*Pennisetum purpureum* Schum.), o capim-andropogon (*Andropogon gayanus*) e o urochloa (*Urochloa mosambicensis*), além de híbridos de sorgo (Sá & Silva, 2010).

O capim-buffel é uma planta perene originária da África, apresenta bom valor nutritivo, boa aceitabilidade e rusticidade para ser cultivado em regiões áridas e semiáridas. Pode ser utilizado para o pastejo direto, tanto na época chuvosa quanto na seca (pasto diferido), além de possibilitar a conservação na forma de feno ou silagem, estrategicamente visando sua utilização no período de escassez de alimentos para os animais (Sá & Silva, 2010). Essa é uma alternativa interessante a fim de manter o melhor valor nutritivo da forrageira, observado no período das águas, quando pode chegar até 12% de proteína bruta (PB) (Moreira et al., 2007). Ao serem utilizados em diferimento, os pastos de capim-buffel propiciam baixa produção de

leite, como observado por Santos et al. (2006), que avaliaram o desempenho produtivo de vacas leiteiras Guzará e Girolando alimentadas com capim-buffel diferido (4,32% PB) e observaram produção média de leite de 3,3 litros/dia.

Já a palma forrageira é originada do México, apresenta alto potencial produtivo, superior a 10.000 kg de MS/ha/ano, mas, para tal, necessita de adubação, controle de plantas daninhas e densidade de plantio adequados (Santos et al., 2015). É uma planta rica em carboidratos não fibrosos (CNF) com mais de 61,79%, principalmente a pectina, possui também acima de 60% de NDT e aproximadamente 4% de PB. É usada predominantemente durante o período seco do ano, a fim de suprir as carências em quantidade e qualidade de forragem dessa época, sendo fornecida *in natura* picada ou em pastejo direto, ou ainda na forma de farelo, que consiste na desidratação e desintegração das raquetes (Sá & Silva, 2010). Wanderley et al. (2002) avaliaram a produção de leite de vacas Holandesas alimentadas com diferentes níveis de palma forrageira substituindo silagem de sorgo, e não constataram efeito sobre a produção de leite, cujos valores médios foram de 24,98 e 24,75 kg/dia, para 0 e 36% de inclusão, respectivamente.

2.3 Consumo de alimentos

O consumo voluntário refere-se ao consumo de alimentos à vontade e é o principal fator que afeta o desempenho animal, visto que influencia nos nutrientes que o animal recebe para seu crescimento, saúde e produção (Silva, 2006). Vários mecanismos afetam a ingestão voluntária de alimentos, que, conforme Silva (2006), são o físico, que está relacionado à capacidade de enchimento e distensão do retículo-rúmen causado pelo teor de fibra em detergente neutro (FDN) das dietas; o neuro-hormonal, relacionado com os hormônios que sinalizam a regulação do consumo; e o psicogênico, relacionado à resposta do animal a fatores inibidores ou estimuladores no alimento. Van Soest (2018) afirma que há variação também em função do animal (espécie, categoria, demanda energética, idade, sexo) e das condições ambientais.

2.3.1 Fatores físicos

As limitações físicas estão relacionadas com a degradação do alimento e com o fluxo da digesta pelo trato gastrointestinal. A capacidade de enchimento ou distensão do rúmen é um dos fatores físicos que limitam o consumo de alimentos pelos animais ruminantes, a partir de receptores de tensão localizados na parede ruminal, que detectam a distensão do rúmen pelo peso e volume da digesta e, a partir desse e de outros estímulos, o centro da saciedade estimula o final da refeição (Silva, 2006).

O teor de FDN, que compreende a fração do alimento insolúvel em meio neutro lentamente degradável e/ou indegradável, é a porção que ocupa espaço no trato digestivo dos ruminantes, sendo um dos principais determinantes da regulação física do consumo devido sua baixa velocidade de digestão (Allen, 2000). Detmann et al. (2014) analisaram a regulação da ingestão voluntária em bovinos alimentados à vontade com dietas à base de forrageiras tropicais, através de uma meta-análise com dados publicados no Brasil entre 1990 e 2012, dos quais 53 foram com vacas em lactação e 126 com bovinos de corte confinados. Esses autores concluíram que a ingestão de matéria seca (IMS) diminuiu linearmente conforme o aumento da fração de FDN da dieta, sendo o consumo voluntário regulado pelas limitações físicas e metabólicas dos animais.

Esses mesmos autores afirmaram que o efeito de preenchimento da fibra depende de várias características, como as dimensões das frações indigeríveis e potencialmente degradáveis e a taxa de remoção do rúmen e, portanto, a única estimativa do teor de FDN na dieta não seria útil para entender ou prever o consumo de matéria seca voluntário (Detmann et al., 2014). Às vezes, separar a fração total da FDN em FDN indigestível (FDNi) e FDN potencialmente degradável (FDNpd) pode melhorar as associações com o consumo, como Huhtanen et al. (2007), que observaram que a previsão do índice de consumo de matéria seca melhorou quando fizeram essa divisão. Assim como Oliveira et al. (2011), que realizaram uma meta-análise de seis experimentos para avaliar os efeitos das características químicas e da digestibilidade *in vivo* da FDN (DFDN) sobre o consumo, a digestibilidade e o desempenho de vacas leiteiras em confinamento. Os autores registraram valor médio de 13,2 g/kg PC para silagem de milho e 9,4 g/kg PC para cana-de-açúcar; além disso, relataram que o efeito do teor de FDN depende da fonte utilizada e recomendaram a discriminação qualitativa das

frações da FDN e lignina para sua utilização eficaz em modelos de predição de consumo de matéria seca.

2.3.2 Fatores neuro-hormonais

O sistema nervoso central, mais especificamente o hipotálamo, está diretamente e indiretamente relacionado com o controle dos sistemas envolvidos na ingestão de alimentos pelos animais. O centro que controla o equilíbrio de energia no cérebro é a região ventromedial do hipotálamo (VMH) e sua excitação inibe a ingestão de alimento. A região do hipotálamo lateral (LH) quando estimulada leva ao consumo de alimentos, além de controlar a procura por alimento e o tamanho da refeição (Silva, 2006).

Vários hormônios são indicados como sinalizadores da regulação do consumo, como leptina, insulina, glucagon e colecistoquinina.

A leptina é produzida pelo tecido adiposo e está envolvida com o controle do consumo, pois leva informações para o cérebro da quantidade de energia corporal depositada na forma de gordura e ativa, por conseguinte, o centro da saciedade (Forbes, 2007). Quando a ingestão de alimento é restrita, a concentração de leptina cai imediatamente antes que ocorra perda de peso. Por outro lado, quando ocorre a superalimentação, ocorre aumento nas concentrações de leptina, que vai atuar como supressor do apetite, reduzindo a fome e aumentando a sensação de saciedade após as refeições. Além disso, a leptina ajuda a regular o metabolismo energético, estimulando o corpo a queimar gordura para obter energia (Silva, 2006).

A insulina é produzida no pâncreas e estimula a secreção de leptina; portanto, também atua como inibidor do consumo. O glucagon, também sintetizado no pâncreas, parece ter efeitos sobre a saciedade a partir da glicogenólise no fígado; no entanto, existem poucos estudos sobre o consumo alimentar em ruminantes. Já a colecistoquinina (CCK) é um neuropeptídeo produzido no intestino delgado, que estimula a produção e a liberação do suco pancreático; e na regulação do consumo, contribui para a saciedade, pois inibe o esvaziamento gástrico e reduz a ingestão de alimento (Silva, 2006).

2.3.3 Fatores psicogênicos

O mecanismo psicogênico sobre o consumo de alimentos envolve respostas no comportamento do animal a fatores inibidores ou estimuladores no alimento, ou no manejo alimentar, que não estão relacionados ao valor energético ou ao efeito de enchimento da dieta. Fatores como sabor, odor, textura, aparência visual do alimento, *status* emocional do animal, interações sociais e o aprendizado podem modificar a intensidade do consumo de alimentos (Mertens, 1994).

O fator que possui maior implicação na regulação psicogênica do consumo de alimentos é a aceitabilidade. De acordo com Mertens (1994), é definida como a característica do alimento relacionada à aceitação olfativa, visual e gustativa pelos animais, e afeta a preferência por um alimento quando vários estão disponíveis. Kolling (2016) avaliou a inclusão de diferentes doses de extrato de orégano (*Origanum vulgare*) no concentrado de novilhas holandesas e observou que a aceitabilidade do concentrado com 7,5 g de extrato de orégano (EO) foi menor comparado com o controle e as doses de 2,5 e 5 g de EO, já que, mesmo os animais tendo demorado menos tempo para acessar o cocho, o consumo do concentrado foi 10% menor. Essa menor aceitabilidade provavelmente ocorreu em função do odor e sabor mais acentuado, e o fato de terem sido colocados em cima da dieta totalmente misturados provavelmente fez com que os animais percebessem o odor e o sabor do extrato.

2.3.4 Fatores relacionados ao animal

O peso corporal (PC) é o fator determinante no consumo de matéria seca de bovinos, uma vez que a capacidade de consumo dos animais varia com o PC e com a taxa de ganho de peso. Muitas vezes, o consumo é expresso em função do tamanho metabólico, assumindo que o consumo é função dos requisitos metabólicos. O PC do animal refere-se ao seu volume e é expresso em quilos, enquanto o peso metabólico (PM) relaciona-se com a superfície corporal e, geralmente, corresponde ao peso corporal elevado ao valor de 0,75 (Mertens, 1994).

Normalmente, com o incremento do PC, ocorre aumento do consumo diário de matéria seca, pois animais mais pesados apresentam maior capacidade do trato gastrointestinal e necessitam de maior quantidade de energia para manutenção. Entretanto, quando expresso em porcentagem do PC, o consumo reduz conforme o aumento do peso

corporal, o que está relacionado ao fato de que animais de maior tamanho corporal apresentam menor superfície corporal relativa (superfície corporal/peso corporal); logo, são menos exigentes em energia por unidade de peso corporal (Kleiber, 1975).

Em relação ao grupo genético e à classe sexual, o NRC (2001) relaciona a capacidade de ingestão de alimentos ao tamanho corporal dos animais e cita que animais da raça Holandesa e seus cruzamentos com raças britânicas de corte são exemplos de animais com capacidade de consumir maior quantidade de alimentos, em relação ao seu peso corporal. A capacidade de ingestão de alimentos do animal está ainda associada ao seu potencial genético para crescimento. Desse modo, animais com maior potencial genético para crescimento e, portanto, maior demanda nutricional, poderiam apresentar maior consumo alimentar.

2.4 Modelos de predição de consumo de matéria seca

Quigley et al. (1986) utilizaram peso corporal, ganho de peso corporal, concentração de nutrientes digestíveis totais da ração, temperatura ambiente, interação e peso corporal metabólico como variáveis independentes na regressão múltipla e validação cruzada para prever o consumo de matéria seca de novilhas holandesas. O modelo preditivo foi responsável por 59% da variação total na ingestão diária de matéria seca em animais individuais.

$$\begin{aligned} CMS(\text{kg}/\text{dia}) = & -29,86 + (-0,0000154 \times PC^2) + (0,157 \times PC^{0,75})(2,09 \times GMD) \\ & + (-0,118 \times GMD^2) + (0,73 \times NDT) + (-0,0048 \times NDT^2) \\ & + (-0,0014 \times PC \times GMD) + (-0,019 \times NDT \times GMD) \end{aligned}$$

Em que: PC = peso corporal (kg), GMD = ganho médio diário (kg/dia), NDT = nutrientes digestíveis totais da dieta (% MS).

O NRC (2001) testou as equações de CMS de Quigley et al. (1986), Stallings et al. (1985) e do NRC gado de corte (1996) em avaliação inicial usando dados de New Hampshire e Minnesota, nos quais a composição da dieta, o crescimento da novilha e o CMS foram medidos ao longo de vários meses. Com base no ajuste dos dados da avaliação inicial e da validação, a

equação do NRC para bovinos de corte foi recomendada para prever o CMS de novilhas Holandesas em crescimento e não lactantes.

$$CMS(kg/dia) = \frac{PC^{0,75}(0,2435 \times ELM - 0,0466 \times ELM^2 - 0,1128)}{ELM}$$

Em que: ELM = energia líquida da dieta para manutenção (Mcal/kg)

Hoffman et al. (2008) geraram um banco de dados para avaliar as equações de predição do CMS de novilhas leiteiras publicadas anteriormente (NRC, 2001; Quigley et al., 1986), além de desenvolver modelos alternativos. Os efeitos de raça, peso corporal, temperatura e variação da fibra em detergente neutro (FDN) foram utilizados. O CMS de novilhas mestiças foi previsto com razoável precisão pelos dois modelos, mas super ou subestimaram para novilhas leves e pesadas, respectivamente. As equações aprimoradas para animais mestiços foram:

$$\text{Modelo utilizando apenas PC: } CMS (kg/dia) = 12,91 \times [1 - e^{(-0,00295 \times PC)}]$$

$$\text{Modelo utilizando FDN e PC: } CMS (kg/dia) = 13,48 \times [1 - e^{(-0,00271 \times PC)}] - C$$

Em que: $C = 0,0824 \times \{23,11 + [0,07968 \times PC] - [0,00006252 \times (PC)^2]\}$

Oliveira & Ferreira (2016) desenvolveram modelos de predição do CMS de novilhas em condições tropicais usando análises não lineares e lineares, e compararam com os 4 modelos americanos atualmente utilizados (Quigley; NRC; e 2 modelos Hoffman). Raça, PC e GMD foram as variáveis independentes utilizadas. O uso de modelos não lineares aumenta a acurácia e a precisão da predição do CMS para novilhas leiteiras em comparação com os modelos lineares, já que explicou 81% da variação do CMS. Apenas os modelos propostos por Oliveira e Ferreira (2016), o modelo exponencial de Hoffman I (PC como entrada), e o modelo de Quigley foram adequados para a predição do CMS de novilhas leiteiras em crescimento em condições tropicais. Os modelos propostos foram:

$$\text{Não lineares: } CMS (kg/dia) = 0,1175 \times PC^{0,75} - 3,4984 \times e^{(-2,4690 \times GMD)}$$

$$\text{Lineares: } CMS \text{ (kg/dia)} = 8,7147 - 0,2402 \times PC^{0,75} - 0,0027 \times (PC^{0,75})^2 + 3,6050 \times GMD - 1,4168 \times GMD^2$$

2.5 Desempenho animal

O desempenho animal pode ser definido em função do consumo de alimentos, que deve ser em quantidades suficientes para atender às necessidades de manutenção e produção dos animais (NRC, 2001). A ingestão de alimentos é o fator mais importante que determina o desempenho dos animais (Illius & Jessop, 1996), sendo que a produtividade dos ruminantes é dependente da sua capacidade de consumir, extrair, metabolizar e absorver os nutrientes e a energia disponíveis nos alimentos (Allen, 1996; Mertens, 1994). O principal objetivo na criação de novilhas de reposição é a obtenção de ganho de peso suficiente para alcançar o peso de cobertura o mais cedo possível e, conseqüentemente, atingir a idade ao primeiro parto o quanto antes (NRC, 2001).

Na maioria dos rebanhos de gado leiteiro, a média de idade ao primeiro parto é entre 24 e 30 meses, com peso corporal ideal entre 55 e 60% do peso corporal maduro (PCM) na inseminação (Van Amburgh et al., 2019). A variável mais importante que pode ser manipulada em novilhas de reposição durante a fase pré-puberdade até a prenhez é a taxa de crescimento, que está inversamente relacionada com a idade de início da puberdade, e pode influenciar a idade reprodutiva, idade ao primeiro parto, produtividade ao longo da vida e custos de alimentação (Erickson et al., 2020; Heinrichs et al., 2017; Van Amburgh et al., 2019).

Vários estudos investigaram o efeito do ganho médio diário (GMD) pré-púbere na produção de leite. Zanton & Heinrichs (2005) e Heinrichs et al. (2017) afirmaram que aproximadamente 800 g/dia é a taxa de crescimento pré-púbere ideal. Ganhos excessivos podem ter influência negativa no crescimento mamário e, conseqüentemente, na produção futura de leite (Sejrsen & Purup, 1997). De acordo com o NRC (2001), essa influência negativa está relacionada com o desequilíbrio entre energia e proteína que pode ocorrer em dietas para altos ganhos de peso, que leva ao acúmulo excessivo de gordura na glândula mamária em vez de tecido secretor, e prejudica a produção futura das vacas leiteiras. Da mesma forma, ganhos muito baixos impactam negativamente a capacidade de desempenho futuro das novilhas. Davis Rincker et al. (2011) demonstraram que novilhas com ganhos de 440 g/dia

apresentaram atraso no início da puberdade quando comparadas a novilhas com ganhos de 680 g/dia e, como resultado, a idade ao primeiro parto foi maior.

Mais recentemente, Gelsinger et al. (2016), em estudo de meta-análise, observaram que a nutrição adequada da novilha antes do desmame contribuiu positivamente na produção de leite e seus componentes aos 305 dias. Os autores relataram que a taxa de crescimento entre 300 e 500 g/dia teve pouco efeito na primeira lactação, mas os efeitos aumentaram à medida que a taxa de crescimento elevou-se de 500 para 900 g/dia. Chester-Jones et al. (2017) verificaram que o peso corporal (PC) e o ganho de peso médio diário (GMD) às 6 e 8 semanas influenciaram positivamente a produção na primeira lactação. Para cada 1 kg de GMD de 6 semanas, a produção de leite de 305 dias aumentou em 544 kg durante a primeira lactação.

O desenvolvimento da novilha após o acasalamento deve-se concentrar na manutenção de taxas de crescimento adequadas, minimizando os ganhos em excesso de condição corporal. À medida que as novilhas amadurecem, a taxa de deposição de tecido magro diminui enquanto a taxa de deposição de tecido adiposo aumenta e pode ocorrer o supercondicionamento. O excesso de deposição de tecido adiposo durante esse período resulta em efeitos negativos nas novilhas durante a transição para a lactação, como aumento de problemas metabólicos, distocia fetal, e menor produção de leite (Akins, 2016). O escore de condição corporal (ECC) é um método simples para o monitoramento da condição do rebanho, sendo que um escore de 3,5 a 4,0 é o desejado para animais mestiços ao parto, e de 2,5 a 3,0 aos 30 dias de lactação (Manzoor et al., 2018).

Monitorar o desenvolvimento corporal do animal é um método prático e simples para avaliar o planejamento de criação das novilhas. As mais importantes medidas de acompanhamento do desenvolvimento corporal são o peso corporal, perímetro torácico, altura na cernelha, altura e largura na garupa, e as correlações entre essas avaliações, além do ganho de peso médio diário (GMD) (Hoffman, 1997; Heinrichs et al., 2007). No entanto, as alturas na cernelha e na garupa isoladamente não indicam se o crescimento corporal e a maturidade fisiológica das novilhas são adequados, mas, se forem utilizadas em conjunto com outros parâmetros zootécnicos, podem auxiliar na avaliação do desenvolvimento desses animais (Oliveira et al., 2009).

Diferentemente do perímetro torácico, as avaliações da altura na cernelha e da largura da garupa são pouco influenciadas pelo escore da condição corporal, e reflete o real crescimento esquelético, sendo consideradas importantes na avaliação do desenvolvimento

(Heinrichs et al., 2007). De acordo com Lagrotta et al. (2010), a altura na garupa é a característica que apresenta maior potencial de resposta à seleção genética para características morfológicas, pois se trata de característica de alta herdabilidade. Além de ter relação com reprodução, facilidade de parto e correlação com tamanho de úbere.

Por outro lado, conforme Radcliff et al. (1997), somente as informações relacionadas ao peso corporal não são capazes de caracterizar o animal, visto que o animal pode possuir estatura menor e ser mais pesado, mas apresentar maior peso que um animal de estatura maior e mais leve. Do mesmo modo, Rocha et al. (2003) afirma que o peso corporal deve ser avaliado em conjunto com outra medida linear de tamanho corporal, como a altura na garupa, para que se obtenham resultados confiáveis na determinação do tamanho à maturidade, uma vez que o peso pode apresentar flutuações periódicas. Diante disso, a altura na cernelha, altura na garupa, perímetro torácico e comprimento corporal são medidas utilizadas para estimar o tamanho do esqueleto, que é de extrema relevância ao parto, tendo o propósito de evitar distocia ou desordens metabólicas após o parto, já que novilhas menores e mais pesadas são mais susceptíveis a apresentar esses problemas (Radcliff et al., 1997).

A composição corporal está diretamente relacionada à taxa de crescimento. Portanto, é importante ressaltar os efeitos da condição corporal ou composição corporal ao parto na produção de leite. Uma condição corporal mais elevada pode provocar efeito negativo no desempenho do gado leiteiro pela diminuição na produção de leite, sugerindo que, à medida que a gordura corporal ou o ECC aumenta próximo ao parto, a produção de leite é inversamente relacionada (Douglas et al., 2006; Rico et al., 2015). Novilhas muito leves em peso corporal irão priorizar nutrientes para o crescimento em detrimento da produção de leite, enquanto novilhas obesas terão respostas metabólicas pós-parto semelhantes às vacas maduras que procriam com maior escore de condição corporal (ECC) e teor de gordura corporal. As metas visam atingir um peso pós-parto de 82 a 85% do PCM do rebanho, assim, qualquer valor nesse intervalo é provavelmente aceitável para otimizar produção de leite na primeira lactação e minimizar a partição de nutrientes para o crescimento. A utilização do peso corporal maduro (PCM) ao invés de usar um valor populacional para ajustar o peso à maturidade refere-se ao fato de que o PCM pode variar entre os rebanhos devido a diferenças genéticas e ambientais (Van Amburgh et al., 2019).

2.6 Modelos de predição de desempenho

Heinrichs et al. (1992) investigaram as relações entre várias medidas de crescimento na previsão do peso corporal e altura na cernelha de novilhas holandesas. As regressões do peso corporal, incluindo os efeitos de uma única variável independente (perímetro torácico, altura na cernelha, largura do quadril ou comprimento do corpo) indicaram que cada medida seria útil para prever o peso corporal ($R^2 > 0,95$). Regressões que consideraram mais de uma característica pouco acrescentaram às correlações múltiplas encontradas com apenas uma variável, que já eram altas. Em situações de manejo para as quais o peso corporal ou a altura na cernelha não podem ser medidos, várias outras características podem ser usadas para estimar essas medidas corporais com precisão.

Reis et al. (2008) realizaram estudo para investigar as relações entre o peso corporal e as medidas corporais de altura na garupa (AG), comprimento de garupa (CG), comprimento corporal (CC) e perímetro torácico (PT), em bovinos oriundos principalmente do cruzamento das raças Holandês e Gir. As correlações simples do peso corporal com PT, CC, CG e AG foram respectivamente 0,942; 0,748; 0,902 e 0,573 para novilhas. As equações de predição do peso corporal em função do perímetro torácico para as novilhas foram:

$$PC (kg) = 1.717 - 35,167 \times PT + 0,238978 \times PT^2 - 0,00046260 \times PT^3$$

O peso pode ser estimado por meio de modelo que inclui medidas corporais, sendo o PT a variável explicativa que mais contribui para a aceitação do modelo. Modelos polinomiais para predição do peso com base no perímetro torácico, quando incluído até o termo cúbico, apresentaram alta aderência e foram distintos para as categorias vacas, novilhas e machos.

Oliveira et al. (2013) realizaram estudo com o objetivo de desenvolver equações para prever o peso corporal (PC) de novilhas leiteiras mestiças por meio de medidas biométricas e comparar com os modelos de Heinrichs et al. (1992) e Reis et al. (2008). Os dados incluíam 150 medidas de peso corporal e medidas biométricas como perímetro torácico (PT), altura da cernelha (AC) e altura do quadril (AQ). Três equações não lineares foram ajustadas:

$$PC (kg) = 0,00058 \times PT^{2,6135}$$

$$PC (kg) = 0,000618 \times PT^{2,7362}$$

$$PC (kg) = 0,000196 \times AQ^{2,8793}$$

Apenas o modelo proposto usando perímetro torácico previu com precisão o peso corporal. Os modelos de Heinrichs e Reis utilizados para comparação não estimaram o peso com precisão. O coeficiente de correlação (R^2) do modelo PT-não linear proposto foi de 0,930, e quando comparado com os modelos de Heinrichs (0,845) e Reis (0,708), confirmam a maior acurácia e precisão da nova equação para predição do PC em novilhas leiteiras mestiças Holandês-Zebu.

Hurst et al. (2021) investigaram se algumas variáveis coletadas durante o pré-desmame poderiam ser usadas para prever o peso corporal futuro, aos 400 dias, de novilhas holandesas de reposição, utilizando polinômio ortogonal de terceira ordem para modelar as curvas de peso corporal. As variáveis consumo de leite, peso ao nascer, escore de composição corporal (ECC), incidência de pneumonia e incidência de diarreia afetaram significativamente ($P < 0,05$) o peso predito das novilhas. A equação preditiva final foi:

$$PC_{(400d)} = 193,14 + 0,55 \times (\text{consumo de leite/L}) - 0,0004 \times (\text{consumo de leite/L})^2 \\ + 1,66 \times (\text{peso ao nascer/kg}) + \text{incidência de pneumonia} \\ + \text{incidência de diarreia} + 8,53 \times ECC$$

Os autores concluíram que as variáveis coletadas durante a fase de pré-desmame influenciam em mais de 25% na variação do peso vivo. É importante ressaltar que essa equação preditiva representa essa única fazenda leiteira. Pesquisas futuras devem ser feitas para entender a melhor forma de implementar esse modelo com base na coleta de dados de uma fazenda individual.

Silva et al. (2021) desenvolveram e validaram equações para estimar o crescimento de novilhas leiteiras holandesas em clima tropical utilizando medidas de altura na cernelha, peso corporal (PC) e idade. Quatro modelos foram avaliados: PC em função da idade ($PC \sim I$), relação PC/altura em função da idade ($PC:H \sim I$), PC em função da altura ($PC \sim H$) e altura em função da idade ($H \sim I$). A relação linear de $PC \sim I$ e $PC:H \sim I$ foi estimada, respectivamente, pelas equações:

$$PC = 42,65 + 0,62 \times I \\ PC:H = 0,70 + 0,0041 \times I$$

Em que: PC:H = Relação PC/estatura (kg/cm) e I = idade (dias).

Foram desenvolvidas equações para estimar a altura dos animais menores e maiores de 806 dias, respectivamente:

$$H = 78,15 + 0,150 \times I - 0,00009 \times I^2$$
$$H = 78,15 + 0,150 \times cvx - 0,00009 \times cvx^2$$

Em que: H = altura (cm) e cvx = 806 (valor crítico em dias)

Adicionalmente, o modelo exponencial de PC~H foi estimado pela seguinte equação:

$$PC \sim H = 4,25 \times \exp^{(0,034 \times H)}$$

Em que: PC (kg) e H = altura (cm)

No geral, todas as equações desenvolvidas tiveram acurácia e precisão muito altas. Esses modelos demonstraram que o peso corporal e a relação peso corporal/estatura aumentam linearmente em função da idade, enquanto o peso corporal segue padrão de crescimento exponencial em função da altura.

Busanello et al. (2022) estimaram e compararam curvas de crescimento baseadas em peso corporal, altura do quadril e altura na cernelha de animais mestiços criados em condições brasileiras. Também foram modeladas e descritas as taxas de crescimento, peso corporal maduro (PCM), idade, peso e altura recomendada ao primeiro acasalamento e primeiro parto. A idade recomendada ao primeiro acasalamento e ao primeiro parto foi de 18 e 27 meses, respectivamente. O PCM dos animais mestiços foi de 607 kg, atingindo o peso recomendado para o primeiro acasalamento, porém, para o primeiro parto não foi alcançado. O GMD do desmame ao acasalamento foi de 530 g/dia e da concepção ao primeiro parto foi de 420 g/dia para os animais mestiços. As alturas no quadril foram de 130 e 137 cm, e as alturas na cernelha, 125 e 134 cm, no acasalamento e no primeiro parto, respectivamente. Os autores concluíram que as medidas de altura (cernelha e quadril), juntamente com o peso corporal, são fortemente recomendadas para avaliar o crescimento corporal das novilhas ao longo de sua vida.

REFERÊNCIAS

- Akins, M.S., 2016. Dairy Heifer Development and Nutrition Management. *Veterinary Clinics of North America* 32, 303–317. <https://doi.org/10.1016/j.cvfa.2016.01.004>
- Allen, M.S., 2000. Effects of diet on short-term regulation of feed intake by lactating dairy cattle. *J Dairy Sci* 83, 1598–1624. [https://doi.org/10.3168/jds.S0022-0302\(00\)75030-2](https://doi.org/10.3168/jds.S0022-0302(00)75030-2)
- Allen, M.S., 1996. Physical constraints on voluntary intake of forages by ruminants. *J Anim Sci* 74, 3063–3075.
- Azevedo, R.A. de, Felix, M.T., Pires Júnior, O. de S., Almeida, A.C. de, Duarte, E.R., 2011. Perfil de propriedades leiteiras ou com produção mista no norte de Minas Gerais. *Revista Caatinga* 24, 153–159.
- Azevêdo, J.A.G., de Campos Valadares Filho, S., dos Santos Pina, D., Chizzotti, M.L., Valadares, R.F.D., 2010. Meta-análise do consumo de matéria seca em bovinos Nelore e mestiços. *Revista Brasileira de Zootecnia* 39, 1801–1809. <https://doi.org/10.1590/S1516-35982010000800024>
- Bareille, N., Beaudeau, F., Billon, S., Robert, A., Faverdin, P., 2003. Effects of health disorders on feed intake and milk production in dairy cows. *Livest Prod Sci* 83, 53–62. [https://doi.org/10.1016/S0301-6226\(03\)00040-X](https://doi.org/10.1016/S0301-6226(03)00040-X)
- Barros, L.J.A. de, Andrade Ferreira, M. de, Oliveira, J.C.V. de, Santos, D.C. dos, Chagas, J.C.C., Alves, A.M.S.V., Silva, A.E.M. da, Freitas, W.R., 2017. Replacement of Tifton hay by spineless cactus in Girolando post-weaned heifers' diets. *Trop Anim Health Prod* 50, 149–154. <https://doi.org/10.1007/s11250-017-1415-4>
- Braga, A. de P., Ludemir, T.B., Carvalho, A.C.P. de L.F., 2000. Redes neurais artificiais. Teorias e aplicações, 1st ed. Livros Técnicos e Científicos Editora S.A., Rio de Janeiro.
- Busanello, M., Sousa, D.G. de, Mendonça, F.A.C., Daley, V.L., Almeida, R. de, Bittar, C.M.M., Lanna, D.P.D., 2021. Feed intake of growing dairy heifers raised under tropical conditions: A model evaluation using meta-analysis. *Animals* 11, 3181. <https://doi.org/10.3390/ani11113181>
- Busanello, M., Sousa, D.G., Poczynek, M., Almeida, R. de, Bittar, C.M.M., Mendonça, F.A.C., Lanna, D.P.D., 2022. Body growth of replacement dairy heifers from 3 distinct genetic groups from commercial Brazilian dairy herds. *J Dairy Sci* 105, 3222–3233. <https://doi.org/10.3168/jds.2021-21197>
- Cavero, D., Tölle, K.H., Henze, C., Buxadé, C., Krieter, J., 2008. Mastitis detection in dairy cows by application of neural networks. *Livest Sci* 114, 280–286. <https://doi.org/10.1016/j.livsci.2007.05.012>
- Chester-Jones, H., Heins, B.J., Ziegler, D., Schimek, D., Schuling, S., Ziegler, B., de Ondarza, M.B., Sniffen, C.J., Broadwater, N., 2017. Relationships between early-life growth, intake, and birth season with first-lactation performance of Holstein dairy cows. *J Dairy Sci* 100, 3697–3704. <https://doi.org/10.3168/jds.2016-12229>
- Cole, J.B., Silva, M.V.G.B. da, 2016. Genomic selection in multi-breed dairy cattle populations. *Revista Brasileira de Zootecnia* 45, 195–202. <https://doi.org/10.1590/S1806-92902016000400008>
- Davis Rincker, L.E., VandeHaar, M.J., Wolf, C.A., Liesman, J.S., Chapin, L.T., Weber Nielsen, M.S., 2011. Effect of intensified feeding of heifer calves on growth, pubertal age, calving age, milk yield, and economics. *J Dairy Sci* 94, 3554–3567. <https://doi.org/10.3168/jds.2010-3923>
- Detmann, E., Gionbelli, M.P., Huhtanen, P., 2014. A meta-analytical evaluation of the regulation of voluntary intake in cattle fed tropical forage-based diets. *J Anim Sci* 92, 4632–4641. <https://doi.org/10.2527/jas.2014-7717>
- Douglas, G.N., Overton, T.R., Bateman, H.G., Dann, H.M., Drackley, J.K., 2006. Prepartal plane of nutrition, regardless of dietary energy source, affects periparturient metabolism and dry matter intake in Holstein cows. *J Dairy Sci* 89, 2141–2157. [https://doi.org/10.3168/jds.S0022-0302\(06\)72285-8](https://doi.org/10.3168/jds.S0022-0302(06)72285-8)

- Erickson, P.S., Anderson, J.L., Kalscheur, K.F., Lascano, G.J., Akins, M.S., Heinrichs, A.J., 2020. Symposium review: Strategies to improve the efficiency and profitability of heifer raising. *J Dairy Sci* 103, 5700–5708. <https://doi.org/10.3168/jds.2019-17419>
- Forbes, J.M., 2007. A personal view of how ruminant animals control their intake and choice of food: Minimal total discomfort. *Nutr Res Rev* 20, 132–146. <https://doi.org/10.1017/S0954422407797834>
- Gelsinger, S.L., Heinrichs, A.J., Jones, C.M., 2016. A meta-analysis of the effects of preweaned calf nutrition and growth on first-lactation performance. *J Dairy Sci* 99, 6206–6214. <https://doi.org/10.3168/jds.2015-10744>
- Haykin, S., 2009. *Neural Networks and Learning Machines*, 3rd ed. Pearson Education, New Jersey. https://doi.org/10.1007/978-3-030-44146-3_14
- Heinrichs, A.J., Erb, H.N., Rogers, G.W., Cooper, J.B., Jones, C.M., 2007. Variability in Holstein heifer heart-girth measurements and comparison of prediction equations for live weight. *Prev Vet Med* 78, 333–338. <https://doi.org/10.1016/j.prevetmed.2006.11.002>
- Heinrichs, A.J., Rogers, G.W., Cooper, J.B., 1992. Predicting Body Weight and Wither Height in Holstein Heifers Using Body Measurements. *J Dairy Sci* 75, 3576–3581. [https://doi.org/10.3168/jds.S0022-0302\(92\)78134-X](https://doi.org/10.3168/jds.S0022-0302(92)78134-X)
- Heinrichs, A.J., Zanton, G.I., Lascano, G.J., Jones, C.M., 2017. A 100-Year Review: A century of dairy heifer research. *J Dairy Sci* 100, 10173–10188. <https://doi.org/10.3168/jds.2017-12998>
- Hoffman, P.C., 1997. Optimum Body Size of Holstein Replacement Heifers. *J Anim Sci* 75, 836–845. <https://doi.org/10.2527/1997.753836x>
- Hoffman, P.C., Weigel, K.A., Wernberg, R.M., 2008. Evaluation of equations to predict dry matter intake of dairy heifers. *J Dairy Sci* 91, 3699–3709. <https://doi.org/10.3168/jds.2007-0644>
- Huhtanen, P., Rinne, M., Nousiainen, J., 2007. Evaluation of the factors affecting silage intake of dairy cows: a revision of the relative silage dry-matter intake index. *Animal* 1, 758–770. <https://doi.org/10.1017/S175173110773673X>
- Hurst, T.S., Lopez-Villalobos, N., Boerman, J.P., 2021. Predictive equations for early-life indicators of future body weight in Holstein dairy heifers. *J Dairy Sci* 104, 736–749. <https://doi.org/10.3168/jds.2020-18560>
- IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Pesquisa da Pecuária Municipal (PPM). Produção de origem animal, por tipo de produto. Sistema IBGE de Recuperação Automática – SIDRA. Rio de Janeiro: IBGE, 2021. Disponível em: <https://sidra.ibge.gov.br/tabela/74#resultado>. Acesso em: 28 abr. 2023.
- Illius, A.W., Jessop, N.S., 1996. Metabolic constraints on voluntary intake in ruminants. *J Anim Sci* 74, 3052–3062.
- Kleiber, M., 1975. Metabolic turnover rate: a physiological meaning of the metabolic rate per unit body weight. *J Theor Biol* 53, 199–204. [https://doi.org/10.1016/0022-5193\(75\)90110-1](https://doi.org/10.1016/0022-5193(75)90110-1)
- Kolling, G.J., 2016. EXTRATOS DE ORÉGANO E CHÁ VERDE COMO ADITIVOS PARA BOVINOS LEITEIROS. Universidade Federal do Rio Grande do Sul.
- Lagrotta, M.R., Euclides, R.F., Verneque, R. da S., Santana Júnior, M.L., Pereira, R.J., Torres, R. de A., 2010. Relação entre características morfológicas e produção de leite em vacas da raça Gir. *Pesqui Agropecu Bras* 45, 423–429. <https://doi.org/10.1590/S0100-204X2010000400011>
- Manzoor, A., Untoo, M., Zaffar, B., Afzal, I., Fayaz, A., Dar, Z.A., Shafiq, S., 2018. Performance profile of dairy animals under compromise with dynamics in body condition score. A review. *Journal of Animal Health and Production* 6, 81–85. <https://doi.org/10.17582/journal.jahp/2018/6.3.80.85>
- Meckbach, C., Tiesmeyer, V., Traulsen, I., 2021. A promising approach towards precise animal weight monitoring using convolutional neural networks. *Comput Electron Agric* 183. <https://doi.org/10.1016/j.compag.2021.106056>
- Mendes Neto, J., Campos, J.M. de S., Valadares Filho, S. de C., Lana, R. de P., Queiroz, A.C. de, Euclides, R.F., 2007. Consumo, digestibilidade, desempenho, desenvolvimento ponderal e economicidade de dietas com polpa cítrica em substituição ao feno de capim-tifton 85 para

- novilhas leiteiras. *Revista Brasileira de Zootecnia* 36, 626–634. <https://doi.org/10.1590/s1516-35982007000300016>
- Menezes, I.R., Almeida, A.C. de, Pinto, M.S., Velasco, F.O., Maia, F.P., Rodrigues, G.V., 2014. Caracterização de Unidades Agrícolas Familiares Produtoras de Leite no Norte do Estado de Minas Gerais. *Revista do Instituto de Laticínios Cândido Tostes* 69, 153–163. <https://doi.org/10.14295/2238-6416.v69i3.342>
- Mertens, D.R., 1994. Regulation of forage intake, in: George, C., Fahey, Jr., Collins, M., Mertens, David.R. (Eds.), *Forage Quality, Evaluation, and Utilization*. American Society of Agronomy, Lincoln, pp. 450–493. <https://doi.org/10.1201/9781351070218>
- Moreira, J.N., Lira, M.D.A., Santos, M.V.F. dos, Araújo, G.G.L. de, Silva, G.C. da, 2007. Potencial de produção de capim buffel na época seca no semi-árido pernambucano. *Revista Caatinga* 20, 20–27.
- NRC, 1996. *Nutrient Requirements of Beef Cattle*. 7th ed. National Academy Press, Washington D.C.
- NRC, 2001. *Nutrient Requirements of Dairy Cattle*, 7th ed. National Academy Press, Washington D.C.
- Oliveira, A.S., Abreu, D.C., Fonseca, M.A., Antoniassi, P.M.B., 2013. Short communication: Development and evaluation of predictive models of body weight for crossbred Holstein-Zebu dairy heifers. *J Dairy Sci* 96, 6697–6702. <https://doi.org/10.3168/jds.2013-6988>
- Oliveira, A.S., Ferreira, V.B., 2016. Prediction of intake in growing dairy heifers under tropical conditions. *J Dairy Sci* 99, 1103–1110. <https://doi.org/10.3168/jds.2015-9638>
- Oliveira, A.S. de, Detmann, E., Campos, J.M. de S., Pina, D. dos S., Souza, S.M. de, Costa, M.G., 2011. Meta-análise do impacto da fibra em detergente neutro sobre o consumo, a digestibilidade e o desempenho de vacas leiteiras em lactação. *Revista Brasileira de Zootecnia* 40, 1587–1595. <https://doi.org/10.1590/S1516-35982011000700026>
- Oliveira, M.V.M. de, Paula Lana, R. de, Costa Eifert, E. da, Luz, D.F., Vargas, F.M. de, 2009. Desempenho de novilhas holandesas confinadas com dietas com diferentes níveis de monensina sódica. *Revista Brasileira de Zootecnia* 38, 1835–1840. <https://doi.org/10.1590/S1516-35982009000900028>
- Oliveira Júnior, G.A., Chud, T.C.S., Ventura, R. V., Garrick, D.J., Cole, J.B., Munari, D.P., Ferraz, J.B.S., Mullart, E., DeNise, S., Smith, S., Silva, M.V.G.B. da, 2017. Genotype imputation in a tropical crossbred dairy cattle population. *J Dairy Sci* 100, 9623–9634. <https://doi.org/10.3168/jds.2017-12732>
- Pereira Júnior, J. de S., 2007. Nova delimitação do Semiárido Brasileiro, Biblioteca Digital da Câmara dos Deputados. Brasil.
- Quigley, J.D., James, R.E., McGilliard, M.L., 1986. Dry Matter Intake in Dairy Heifers. 2. Equations to Predict Intake of Heifers under Intensive Management. *J Dairy Sci* 69, 2863–2867. [https://doi.org/10.3168/jds.S0022-0302\(86\)80740-8](https://doi.org/10.3168/jds.S0022-0302(86)80740-8)
- Radcliff, R.P., Vandehaar, M.J., Skidmore, A.L., Chapin, L.T., Radke, B.R., Lloyd, J.W., Stanisiewski, E.P., Tucker, H.A., 1997. Effects of Diet and Bovine Somatotropin on Heifer Growth and Mammary Development. *J Dairy Sci* 80, 1996–2003. [https://doi.org/10.3168/jds.S0022-0302\(97\)76143-5](https://doi.org/10.3168/jds.S0022-0302(97)76143-5)
- Reis, G.L., Albuquerque, F.H.M.A.R., Valente, B.D., Martins, G.A., Teodoro, R.L., Ferreira, M.B.D., Monteiro, J.B.N., Almeida e Silva, M. de, Madalena, F.E., 2008. Predição do peso vivo a partir de medidas corporais em animais mestiços Holandês/Gir. *Ciencia Rural* 38, 778–783. <https://doi.org/10.1590/S0103-84782008000300029>
- Rico, J.E., Bandaru, V.V.R., Dorskind, J.M., Haughey, N.J., McFadden, J.W., 2015. Plasma ceramides are elevated in overweight Holstein dairy cows experiencing greater lipolysis and insulin resistance during the transition from late pregnancy to early lactation. *J Dairy Sci* 98, 7757–7770. <https://doi.org/10.3168/jds.2015-9519>
- Rocha, E.D., Andrade, V.J., Euclides Filho, K., Nogueira, E., Figueiredo, G.R., 2003. Tamanho de vacas Nelore adultas e seus efeitos no sistema de produção de gado de corte. *Arq Bras Med Vet Zootec* 55, 474–479. <https://doi.org/10.1590/s0102-09352003000400014>
- Sá, I.B., Silva, P.C.G. da, 2010. Semiárido Brasileiro: pesquisa, desenvolvimento e inovação, Embrapa Semiárido. Embrapa Semiárido, Petrolina.

- Santos, C.A. dos, 2012. QUALIDADE DO LEITE DE REBANHOS MISTIÇOS HOLANDÊS E GIR NO NORTE DE MINAS GERAIS E FATORES DE RISCO ASSOCIADOS À MASTITE SUBCLÍNICA. Universidade Federal de Minas Gerais.
- Santos, G.R.A., Guim, A., Ferreira, M.A., Santos, M.V.F., Batista, Â.M. V., Lira, M.A., Veras, R.M.L., 2006. SUPLEMENTAÇÃO DE VACAS LEITEIRAS A PASTO NO PERÍODO SECO NO SERTÃO PERNAMBUCANO. *Archivos de Zootecnia* 55, 239–249.
- Santos, P.M., Vinholis, M. de M.B., Dias-Filho, M.B., Voltolini, T.V., Mittelman, A., Pezzopane, J.R.M., Evangelista, S.R.M., Moura, M.S.B. de, Gomide, C.A. de M., Cavalcante, A.C.R., Corrêa, C.G., Bettiol, G.M., Santos, R.M., Angelotti, F., Oliveira, P.P.A., Souza, F.H., Almeida, I.R. de, Bosi, C., Cruz, P.G. da, Andrade, A.S., Araujo, L.C. de, Pellegrino, G.Q., 2015. Produção animal no Brasil: caracterização, simulação de cenários para pastagens e alternativas de adaptação às mudanças climáticas, 1st ed. Embrapa Pecuária Sudeste, São Carlos.
- Sejrsen, K., Purup, S., 1997. Influence of Prepubertal Feeding Level on Milk Yield Potential of Dairy Heifers: A Review. *J Anim Sci* 75, 828–835. <https://doi.org/10.2527/1997.753828x>
- Silva, A.L., DeVries, T.J., Fernandes, E.C., Marcondes, M.I., 2021. Short communication: Development and evaluation of equations to predict growth of Holstein dairy heifers in a tropical climate. *J Dairy Sci* 104, 525–531. <https://doi.org/10.3168/jds.2020-18624>
- Silva, I.N. da, Spatti, D.H., Flauzino, R.A., Liboni, L.H.B., Alves, S.F. dos R., 2017. Artificial Neural Networks, 1st ed. Springer. https://doi.org/10.1007/978-1-4939-2239_0
- Silva, J.F.C. da, 2006. Mecanismos reguladores do consumo, in: Berchielli, T.T., Pires, A.V., Oliveira, S.G. de (Eds.), *Nutrição de Ruminantes*. FUNEP, Jaboticabal, p. 583.
- Silva, M.V.G.B. da, Ferreira Junior, E., Panetto, J.C. do C., Paiva, L. de C., Machado, M.A., Faza, D.R. de L.R., Daltro, D. dos S., Negri, R., Kluska, S., Martins, M.F., Borges, C.A.V., 2022. Programa de melhoramento genético da Raça Girolando/ Sumário de Touros Resultado do Teste de Progênie (Avaliação genética/genômica). Embrapa Gado de Leite, Juiz de Fora.
- Silvestre, T., Lima, M.A., Santos, G.B. dos, Pereira, L.G.R., Machado, F.S., Tomich, T.R., Campos, M.M., Jonker, A., Rodrigues, P.H.M., Brandao, V.L.N., Marcondes, M.I., 2021. Effects of feeding level and breed composition on intake, digestibility, and methane emissions of dairy heifers. *Animals* 11, 1–11. <https://doi.org/10.3390/ani11030586>
- Souza, M.C., Oliveira, A.S., Araújo, C. V., Brito, A.F., Teixeira, R.M.A., Moares, E.H.B.K., Moura, D.C., 2014. Short communication: Prediction of intake in dairy cows under tropical conditions. *J Dairy Sci* 97, 3845–3854. <https://doi.org/10.3168/jds.2013-7652>
- Stallings, C.C.; Kroll, G.; Kelley, J.C.; McGilliard, M.L. 1885. A computer ration evaluation program for heifers, dry cows, and lactating cows. *J Dairy Sci* 68, 1015–1019. [https://doi.org/10.3168/jds.S0022-0302\(85\)80923-1](https://doi.org/10.3168/jds.S0022-0302(85)80923-1)
- Taylor, C., Guy, J., Bacardit, J., 2022. Prediction of growth in grower-finisher pigs using recurrent neural networks. *Biosyst Eng* 220, 114–134. <https://doi.org/10.1016/j.biosystemseng.2022.05.016>
- Van Amburgh, M.E., Soberon, F., Meyer, M.J., Molano, R.A., 2019. Symposium review: Integration of postweaning nutrient requirements and supply with composition of growth and mammary development in modern dairy heifers. *J Dairy Sci* 102, 3692–3705. <https://doi.org/10.3168/jds.2018-15270>
- Van Soest, P.J., 2018. *Nutritional Ecology of the Ruminant*, 2nd ed. Cornell University.
- Wanderley, W.L., Ferreira, M.D.A., Andrade, D.K.B. de, Veras, A.S.C., Farias, I., Lima, L.E. de, Dias, A.M. de A., 2002. Palma Forrageira (*Opuntia ficus indica* Mill) em Substituição à Silagem de Sorgo (*Sorghum bicolor* (L.) Moench) na Alimentação de Vacas Leiteiras. *Revista Brasileira de Zootecnia* 31, 273–281.
- Zanton, G.I., Heinrichs, A.J., 2005. Meta-analysis to assess effect of prepubertal average daily gain of Holstein Heifers on first-lactation production. *J Dairy Sci* 88, 3860–3867. [https://doi.org/10.3168/jds.S0022-0302\(05\)73071-X](https://doi.org/10.3168/jds.S0022-0302(05)73071-X)

1 **Capítulo 1: 4. Uso de Redes Neurais para predição do consumo e desempenho de novilhas**
2 **leiteiras**

3
4 Larissa Inácio Soares de Oliveira^a, Vicente Ribeiro Rocha Júnior^a, Flávio Pinto Monção^a, Marcos
5 Flávio Silveira Vasconcelos D'Angelo^b, Maria Dulcinéia da Costa^a

6
7 ^a Departamento de Ciências Agrárias, Universidade Estadual de Montes Claros, Minas Gerais,
8 Brasil

9 ^b Departamento de Ciência da Computação, Universidade Estadual de Montes Claros, Minas
10 Gerais, Brasil

11
12 **Resumo**

13 Objetivou-se realizar uma meta-análise para predição do consumo e desenvolvimento
14 ponderal de novilhas mestiças leiteiras no semiárido, utilizando-se a metodologia de redes
15 neurais. Foi desenvolvido um banco de dados a partir de cinco dissertações realizadas na
16 Unimontes, totalizando 159 observações. As variáveis de entrada utilizadas na construção da
17 rede neural foram consumo e digestibilidade dos nutrientes, síntese de proteína microbiana,
18 comportamento ingestivo e desempenho animal, totalizando 31 variáveis aleatórias. As
19 variáveis de saída foram consumo de matéria seca e ganho de peso médio diário. A rede neural
20 empregada foi a *Feed-forward Multilayer Perceptron* (MLP), com algoritmo de
21 retropropagação como processo de treinamento. Foi utilizado o programa computacional
22 Neural Network Toolbox do Matlab® 6.5, em que 70% dos dados foram usados para o
23 treinamento e 30% para validação da rede. Foram realizados dois experimentos, o
24 Experimento 1 previu o ganho de peso médio diário e o Experimento 2 fez a predição do
25 consumo de matéria seca. A rede neural foi eficiente nas predições, tanto pela semelhança
26 com o consumo e ganho de peso real, quanto pelo baixo valor do erro médio quadrático. O
27 consumo de matéria seca real foi 8,33 kg/dia, enquanto a rede neural previu consumo de 8,34
28 kg/dia. Já o ganho de peso real foi de 0,93 kg/dia, enquanto o predito foi 0,98 kg/dia. Ao
29 comparar os valores reais de consumo de matéria seca com algumas equações do NRC,
30 observou-se sub e superestimação do consumo real. Em comparação com o consumo real, o
31 predito pela rede neural artificial e pelas duas equações (NRC 2016 e 2021), a predição que

32 mais se assemelhou à real foi pela rede neural artificial (RNA), em que o erro médio quadrático
33 também foi o menor, mostrando sua alta precisão.

34 **Palavras-chave:** desenvolvimento ponderal, ingestão de alimentos, inteligência artificial,
35 previsão

36

37 **4.1 Introdução**

38 A criação de novilhas de reposição é fundamental para garantir elevada produtividade
39 e longevidade do rebanho nas fazendas leiteiras (Hurst et al., 2021). A taxa de crescimento das
40 novilhas no início da vida pode resultar em idade mais precoce ao primeiro parto e aumento
41 da produção de leite na vida útil das vacas (Soberon et al., 2012) e, conseqüentemente,
42 redução dos custos gerais de criação. Entender quais variáveis afetam o peso corporal pode
43 ajudar os produtores a selecionarem as melhores novilhas de reposição para seu rebanho.

44 As medidas morfométricas como peso corporal, alturas na cernelha e garupa, largura
45 na garupa e comprimento corporal são essenciais na criação de novilhas leiteiras para
46 determinar as necessidades nutricionais e auxiliar na avaliação do crescimento e
47 desenvolvimento corporal. Nesse sentido, é fundamental realizar o acompanhamento dessas
48 medidas ao longo do crescimento dos animais (Heinrichs et al., 2007). Sabe-se que novilhas
49 de primeiro parto possuem exigências nutricionais diferentes de vacas adultas e, se a novilha
50 for mais leve, irá priorizar nutrientes para o seu crescimento em detrimento da produção de
51 leite (Van Amburgh et al., 2019).

52 Uma vez que o desempenho é determinado pelo consumo de alimentos, também é
53 fundamental compreender a capacidade de ingestão pelo animal e os fatores que o afetam. A
54 predição correta do consumo de alimentos pelas novilhas é essencial para otimizar o uso de
55 nutrientes e o desempenho nos sistemas de produção leiteira (Souza et al., 2014). Todavia, a
56 estimativa precisa do consumo de matéria seca (CMS) continua sendo um desafio, devido às
57 dificuldades no uso de modelos preditivos complexos. Os modelos preditivos atuais (Quigley
58 et al., 1986; NRC, 2001; Hoffman et al., 2008) utilizam variáveis relacionadas aos animais (peso
59 corporal e ganho de peso) e à dieta (valor energético e teor de FDN), porém, são poucos os
60 modelos criados para animais mestiços.

61 Várias são as metodologias usadas nas predições de CMS e desempenho das novilhas,
62 sempre gerando modelos matemáticos, definidos como o uso de equações para descrever ou
63 simular processos em um sistema (Dumas et al., 2008). Contudo, não há registros da utilização

64 de redes neurais, que fazem parte da área conhecida como Inteligência Computacional, nas
65 predições de CMS e desempenho das novilhas. Estes são modelos computacionais inspirados
66 na estrutura do sistema nervoso dos seres vivos e são constituídos por neurônios artificiais,
67 tendo desempenho superior aos métodos estatísticos tradicionais quando se trata de
68 estimativa de consumo (Silva et al., 2017).

69 Diante disso, objetiva-se por meio deste trabalho realizar uma meta-análise para
70 predição do consumo e desenvolvimento ponderal de novilhas mestiças leiteiras em condições
71 de semiárido, com a metodologia de redes neurais.

72

73 **4.2 Material e métodos**

74 **4.2.1 Declaração de ética**

75 Os procedimentos de cuidado e manejo dos animais utilizados nos experimentos estão
76 de acordo com as diretrizes da Comissão de Ética no Uso de Animais (CEUA) da Universidade
77 Estadual de Montes Claros.

78

79 **4.2.2 Local do experimento**

80 Um conjunto de dados oriundos de 05 dissertações de mestrado realizadas na
81 Universidade Estadual de Montes Claros (UNIMONTES), Campus Janaúba, totalizando 159
82 observações, foi utilizado para análise conjunta na predição do consumo e desempenho de
83 novilhas mestiças leiteiras.

84 A UNIMONTES está inserida na região do Semiárido Norte-Mineiro localizada no
85 município de Janaúba (coordenadas geográficas: 15 ° 52'38 "S, 43 ° 20'05" W), Minas Gerais.
86 O clima da região, segundo a classificação de Köppen (1948), é do tipo Aw, com chuvas de
87 verão e períodos de seca bem definidos no inverno. A precipitação média anual é inferior a
88 800 mm, com temperatura média anual de 27 °C. O clima é tropical mesotérmico, quase
89 megatérmico, devido à altitude, subúmido e semiárido, com chuvas irregulares, ocasionando
90 longos períodos de seca.

91

92 **4.2.3 Manejo geral dos animais e dietas**

93 Todos os experimentos tiveram duração média de 105 dias, divididos em 5 períodos de
94 21 dias, sendo 17 dias para adaptação dos animais às dietas e ao manejo, e os últimos 4 dias
95 para coleta de dados e amostras. Em cada um deles foram utilizadas 10 novilhas mestiças,

96 distribuídas em 10 baias (3 m de comprimento × 2 m de largura) com superfície de solo
97 compactada e equipada com comedouros de concreto e bebedouros automáticos. Os animais
98 possuíam média de idade de 10 meses ± 4 meses, Peso Corporal Inicial (PCi) médio de 246 kg
99 ± 16,82 kg e composições raciais variando de ½ a ¾ Holandês x Zebu.

100 Ao início dos experimentos, os animais foram vacinados contra clostridioses e
101 enterotoxemias, e, para controle de endo e ectoparasitas, foi aplicada a Abamectina 1% com
102 dosagens ajustadas de acordo com o PCi.

103 Em todos os experimentos, as dietas foram formuladas conforme o NRC (2001) e a
104 relação volumoso:concentrado das dietas experimentais foi de aproximadamente 75:25 na
105 base da matéria seca. As dietas foram fornecidas duas vezes por dia, às 07:00 h e às 14:00 h,
106 em sistema de dieta completa (Total mixed ration-TMR), homogeneizada no cocho. As sobras
107 foram coletadas e pesadas diariamente, pela manhã, antes da primeira alimentação, para
108 ajuste do consumo e a quantidade fornecida foi calculada com base nas sobras, que
109 representaram 5% do total de matéria seca fornecida.

110 Os volumosos utilizados nos experimentos que geraram a base de dados foram o sorgo
111 forrageiro Volumax, sorgo biomassa BRS 716, capim-elefante-BRS-capiaçu, milho, além das
112 associações de alguns destes com palma forrageira, todos adaptados às condições
113 edafoclimáticas características da região.

114 A ureia foi utilizada para correção dos teores de proteína bruta (PB) da fração volumosa
115 das dietas, sendo utilizado um único concentrado nas dietas de cada experimento. Para
116 garantir a manutenção da relação volumoso : concentrado na MS total das dietas e que as
117 mesmas fossem mantidas isoproteicas, os teores de matéria seca (MS) e PB dos volumosos
118 foram analisados semanalmente.

119

120 **4.2.4 Obtenção das culturas**

121 Todos os volumosos foram cultivados na Fazenda Experimental da UNIMONTES. O
122 sorgo Volumax foi colhido aos 110 dias e, o sorgo biomassa BRS 716, aos 160 dias após o
123 plantio. O capim-BRS-capiaçu (*Pennisetum purpureum* Schum) foi estabelecido em 2016 e sua
124 altura na colheita era de aproximadamente 3,9 m aos 110 dias de rebrota.

125 A palma forrageira (*Opuntia cochenillifera*) variedade Gigante foi implantada no ano de
126 2014 e sua colheita foi feita manualmente após o intervalo de um ano do último corte. Já o
127 milho utilizado foi o *Pennisetum glaucum* (L) R. Br. ADR 500, sendo manejado e colhido 120

128 dias após o plantio. Os dados da composição química dos volumosos utilizados estão
129 apresentados na Tabela 1.

130

131 **Tabela 1.** Composição química dos volumosos utilizados nos experimentos da base de dados com base
132 na matéria seca.

Item	Ingredientes*				
	Volumax	BRS 716	BRS capiaçu	Milheto	Palma
	g/kg de matéria seca				
Matéria Seca	333,03	304,02	228,44	226,20	90,90
Proteína Bruta	76,39	63,28	66,75	103,83	51,60
Extrato Etéreo	29,30	26,30	16,75	29,55	19,30
Carboidratos Totais	814,41	831,22	807,01	765,55	798,10
Carboidratos não fibrosos	214,64	171,65	115,51	113,45	508,10
Fibra em detergente neutro	640,50	685,86	696,85	643,23	290,8
FDNcp	598,67	638,17	655,15	574,30	271,4
FDNi	281,45	269,00	334,88	326,30	253,50
Fibra em detergente ácido	349,80	412,55	498,1	395,67	184,20
Lignina	66,43	84,66	96,46	77,83	22,50

133 FDNcp - Fibra insolúvel em detergente neutro corrigida para cinzas e proteína; FDNi – Fibra insolúvel
134 em detergente neutro indigestível; NDT - Nutrientes digestíveis totais.

135

136 4.2.5 Rede Neural Artificial

137 As variáveis de entrada utilizadas na construção da rede neural artificial (RNA) foram
138 o consumo dos nutrientes: proteína bruta, fibra em detergente neutro, nutrientes digestíveis
139 totais, carboidratos não fibrosos, expressos em kg/dia e % do peso corporal (PC). Também
140 foram utilizadas as variáveis relacionadas à digestibilidade da matéria seca e da fibra insolúvel
141 em detergente neutro, síntese de proteína microbiana, comportamento ingestivo, e
142 desempenho animal (medidas de desenvolvimento corporal), totalizando 31 variáveis
143 aleatórias de entrada. As variáveis de desfecho ou saída foram consumo de matéria seca e
144 ganho de peso médio diário.

145 Nesta pesquisa, foi utilizada a rede *Feed-forward Multilayer Perceptron* (MLP). O MLP
146 é uma arquitetura específica de Redes Neurais que inclui camadas ocultas entre os nós de

147 entrada e saída. O processo de treinamento dessa rede emprega o algoritmo de
 148 retropropagação, proposto por Rumelhart et al. (1986). O resumo das etapas do algoritmo de
 149 retropropagação, apresentado em Haykin (1999), através da amostra de treinamento,
 150 $\{(x(n), d(n))\}_{n=1}^N$, onde $x(n)$ é a n -ésima data de entrada e $d(n)$ é a n -ésima data de saída
 151 desejada, como segue:

152 **1. Inicialização:** Assumindo que nenhuma informação prévia está disponível,
 153 escolheram-se os pesos e limiares sinápticos, $\omega_{ji}^{(l)}(n)$, de distribuição uniforme cuja média é
 154 zero e cuja variância é escolhida para fazer o desvio-padrão dos campos locais induzidos dos
 155 neurônios na transição entre as partes linear e saturada da função de ativação, ϕ .

156 **2. Apresentação de Exemplos de Treinamento:** Apresentou-se a rede neural um
 157 *epochs* de exemplos de treinamento. Para cada exemplo no conjunto $\{(x(n), d(n))\}_{n=1}^N$,
 158 ordenado de alguma forma, executou-se a sequência de cálculos progressivos e inversos
 159 descritos nos pontos 3 e 4, respectivamente.

160 **3. Computação avançada:** Foi deixado um exemplo de treinamento no *epochs* a ser
 161 denotado por $(x(n), d(n))$, com o vetor de entrada $x(n)$ aplicado à camada de entrada de
 162 nós sensoriais e o vetor de resposta desejado $d(n)$ apresentado à camada de saída de nós de
 163 computação. Calculou-se o campo local induzido e os sinais de funções da rede neural,
 164 avançando pela rede, camada por camada. O campo local induzido $v_j^{(l)}(n)$ para o neurônio j
 165 na camada l é:

$$166 \quad v_j^{(l)}(n) = \sum_{i=0}^{m_0} \omega_{ji}^{(l)}(n) y_i^{(l-1)}(n)$$

167 Em que: $y_i^{(l-1)}(n)$ é o sinal de saída (função) do neurônio i na camada anterior $(l - 1)$ na
 168 iteração n ; e $\omega_{ji}^{(l)}(n)$ é o peso sináptico do neurônio i na camada l que é alimentado pelo
 169 neurônio i na camada $(l - 1)$. Para $i = 0$, temos $y_0^{(p-1)}(n) = +1$ e $\omega_{j0}^{(l)} = b_j^{(l)}$ é o viés
 170 aplicado ao neurônio j na camada l . O sinal de saída do neurônio j na camada l é:

$$171 \quad y_j^{(l)} = \phi_j(v_j(n))$$

172 Se o neurônio j estiver na primeira camada oculta (ou seja, $l = 1$), definiu-se:

$$173 \quad y_j^{(0)}(n) = x_j(n)$$

174 Em que: $x_j(n)$ é o j -ésimo elemento do vetor de entrada $x(n)$. Se o neurônio j estiver na
 175 camada de saída (ou seja, $l = L$, onde L é o número de camadas de rede), definiu-se:

176
$$y_j^{(L)} = o_j(n)$$

177 Calcular o sinal de erro:

178
$$e_j(n) = d_j(n) - o_j(n)$$

179 Em que: $d_j(n)$ é o j-ésimo elemento do vetor de saída desejado $d(n)$.

180 **4. Computação Reversa.** Calculou-se os δ s (isto é, gradientes locais) da Rede Neural,
181 definidos por

182
$$\delta_j^{(l)}(n) = \left[\begin{array}{c} e_j^{(l)}(n) \varphi_j'(v_j^{(l)}(n)) \\ v_j^{(l)}(n) \sum_k \delta_k^{(l+1)}(n) \omega_{kj}^{(l+1)}(n) \end{array} \right]$$

183 Em que: o primo em $\varphi_j'(\cdot)$ denota diferenciação em relação ao argumento. Ajustaram-se os
184 pesos sinápticos da Rede Neural na camada l de acordo com a regra delta generalizada
185 (Widrow, 1960a; Widrow, 1960b; Widrow & Hoff, 1960).

186

187
$$\omega_{ji}^{(l)}(n+1) = \omega_{ji}^{(l)}(n) + \alpha [\omega_{ji}^{(l)}(n-1)] + \eta \delta_j^{(l)}(n) y_j^{(l-1)}(n)$$

188

189 Em que: η é a taxa de aprendizado e α é a constante de momento.

190 **5. Iteração:** Iterar os cálculos para frente e para trás nos pontos 3 e 4, apresentando novas
191 épocas de exemplos de treinamento para a Rede Neural até que o critério de parada seja
192 atendido.

193 A Rede Neural Artificial (RNA) do tipo feedforward treinada pelo algoritmo de
194 retropropagação foi usada para realizar dois experimentos. No primeiro, foram utilizadas todas
195 as variáveis de entrada, inclusive o consumo diário de matéria seca, para prever o ganho de
196 peso diário. Já no segundo experimento, também com as mesmas variáveis, inclusive o ganho
197 de peso diário, realizou a previsão consumo de matéria seca.

198 Para medir a acurácia do modelo, foi utilizado o erro médio quadrático conforme:

199
$$erro = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

200 Em que: n é o número de amostras; y_i a amostra real e \hat{y}_i é o valor da amostra estimada pela
201 RNA. Foram feitas 100 previsões para cada amostra nos dois experimentos.

202 Na avaliação do desempenho da rede para o teste e a validação da RNA, utilizou-se o
203 conjunto de dados registrados nos experimentos, sendo que 70% dos dados foram utilizados

204 para o treinamento e 30% para sua validação (Prechelt, 1994; Haykin, 2001). O critério adotado
205 para parada do treinamento foi a combinação de métodos, pelo erro e pelo número de ciclos
206 (*epochs*), encerrando-se o treinamento quando um dos critérios foi atendido. Dessa forma, o
207 treinamento foi encerrado quando houve convergência na superfície do erro médio quadrático
208 (0,005), que consistiu numa análise de performance de predição da rede. Por meio desse erro,
209 esperaram-se valores próximos de zero, visando ao desempenho satisfatório da rede.

210 Para resolução das etapas subsequentes, foi utilizada a Neural Network Toolbox do
211 Matlab® 6.5, aplicando-se a ferramenta computacional exclusiva para redes neurais artificiais,
212 que possui um conjunto de funções predefinidas.

213 Os dados dos experimentos com as novilhas mestiças leiteiras utilizados como banco
214 de dados para o estudo foram descritos através de Estatística Descritiva, utilizando-se o
215 software estatístico SISVAR® (Ferreira, 2008).

216 Foi realizada também uma análise de relação através do Microsoft Excel 2013 dos
217 valores de consumo reais e preditos pela rede neural artificial com equações já publicadas que
218 estimam o consumo de matéria seca para novilhas, sendo elas:

$$219 \text{ NRC (2016): CMS (kg/dia) = PC}^{0,75} \times (0,2435 \times \text{ELm}) - (0,0466 \times \text{ELm}^2)$$

220 Em que: ELm é a energia líquida para manutenção.

$$221 \text{ NRC (2021): CMS(kg/dia) = 0,022} \times \text{PCM} \times (1 - e^{(-1,54 \times (\text{PC}/\text{PCM}))})$$

222 Em que: PCM é o peso corporal maduro dos animais.

223

224 **4.3 Resultados**

225 A média de consumo de matéria seca das novilhas leiteiras mestiças foi de 8,33 kg/dia,
226 com o menor consumo sendo de 2,18 kg e o maior, 14,22 kg/dia. Da mesma forma, o consumo
227 em função do peso corporal (PC) também apresentou elevada variação, de 1,41 a 5,10%, com
228 média de 3,23% (Tabela 2).

229

230

231

232

233

234

235 **Tabela 2** - Estatística descritiva das variáveis utilizadas na predição do consumo de matéria seca e no desempenho das
 236 novilhas leiteiras mestiças.

	Média	Mediana	Mínimo	Máximo	EPM*
<i>Consumo de nutrientes</i>					
Matéria seca, kg/dia	8,33	8,73	2,18	14,22	0,23
Matéria seca, %PC	3,23	3,23	1,41	5,10	0,04
Proteína bruta, kg/dia	0,82	0,83	0,16	1,79	0,03
Proteína bruta, %PC	0,32	0,31	0,12	0,59	0,007
Fibra insolúvel em detergente neutro, kg/dia	3,32	3,18	0,09	7,00	0,12
Fibra insolúvel em detergente neutro, %PC	1,32	1,29	0,07	2,62	0,04
Carboidratos não fibrosos, kg/dia	1,96	1,75	0,17	4,81	0,10
Carboidratos não fibrosos, %PC	0,71	0,68	0,14	1,57	0,03
Nutrientes digestíveis totais, kg/dia	5,20	5,42	0,73	11,96	0,16
Nutrientes digestíveis totais, %PC	2,00	1,98	0,64	3,37	0,04
Energia metabolizável, Mcal/kg	19,43	20,38	2,74	48,18	0,65
Energia líquida, Mcal/kg	11,75	12,27	1,66	27,95	0,38
<i>Digestibilidade, g/kg</i>					
Matéria seca	714,2	724,7	475,7	907,3	0,80
Fibra insolúvel em detergente neutro	582,0	569,7	411,7	789,0	1,32
<i>Comportamento ingestivo, horas</i>					
Tempo de alimentação	5,62	5,79	3,25	7,92	0,08
Tempo de ruminação	9,66	8,67	3,75	11,17	0,08
Tempo de ócio	9,71	9,58	6,5	15,58	0,12
<i>Desempenho animal, kg</i>					
Peso inicial	264,0	268,3	80	457,0	7,74
Peso final	276,9	287,8	83	477,0	8,02
Ganho de peso diário, kg/dia	0,93	0,86	0,0	2,75	0,04
<i>Síntese de proteína microbiana</i>					
Proteína bruta microbiana, g/dia	365,4	222,5	80,61	1923,0	33,9
Nitrogênio retido, g	72,25	67,35	0,0	215,9	4,8
<i>Medidas morfológicas, cm</i>					
Perímetro torácico inicial	150,5	156,0	102,0	183,0	2,07
Perímetro torácico final	153,4	160,0	102,0	189,0	1,75
Altura na cernelha inicial	121,8	125,0	89,0	142,5	1,33
Altura na cernelha final	122,6	126,8	91,0	142,5	1,06
Altura na garupa inicial	128,4	132,3	92,0	146,5	1,29
Altura na garupa final	129,2	133,5	95,0	148,0	1,04
Comprimento corporal inicial	123,7	126,0	89,0	150,0	1,47
Comprimento corporal final	127,3	129,8	91,0	157,0	1,32

237 *EPM – Erro padrão da média


238 O peso médio inicial das novilhas foi de 264 kg e o peso médio final de,
239 aproximadamente, 277 kg, com uma diferença entre mínimo e máximo bastante elevada
240 (amplitude de 377 e 394 kg, respectivamente), isso porque as novilhas possuíam grande
241 variações nas idades, com animais desde 6 até 14 meses. A média de ganho de peso diário foi
242 de 0,930 kg, com ganho máximo de 2,75 kg, devido à grande variação do peso das novilhas.
243 Em relação às medidas biométricas, as médias de ganho, em cm, foram de 2,82, 0,81, 0,71 e
244 3,56 para perímetro torácico, altura na cernelha, altura na garupa e comprimento corporal,
245 respectivamente (Tabela 2).

246 Foram realizados dois experimentos, sendo que o Experimento 1 estimou o ganho de
247 peso médio diário utilizando-se as variáveis da Tabela 2, e o Experimento 2, também com as
248 mesmas variáveis, fez a predição do consumo de matéria seca. A Tabela 3 mostra o resultado
249 para o erro médio quadrático mínimo, máximo e a média após as 100 simulações realizadas
250 para cada amostra nos dois experimentos.

251
252 **Tabela 3** – Resultados de erro médio quadrático obtidos no Experimento 1 (predição do ganho peso
253 diário) e no Experimento 2 (predição do consumo diário de matéria seca)

	Mínimo	Máximo	Média
Experimento 1	0,0979 Kg	2,6995 Kg	0,3124 Kg
Experimento 2	0,1583 Kg	0,7995 Kg	0,4340 Kg


254
255 Já os gráficos a seguir representam apenas uma das 100 simulações feitas nos
256 experimentos (Figura 1). O primeiro gráfico representa o erro de 01 simulação da predição de
257 ganho de peso, e o segundo, da predição do consumo de matéria seca.



258

Figura 1. Representação gráfica do erro médio quadrático obtido em 1 simulação no Experimento 1 (predição do ganho peso diário) e no Experimento 2 (predição do consumo diário de matéria seca).

259 A predição do ganho de peso médio diário real é representada pela linha azul enquanto
 260 a linha vermelha representa o ganho de peso estimado pela Rede Neural Artificial (Figura 2),
 261 mostrando que a rede foi eficiente nessa predição, visto que as linhas estão praticamente
 262 sobrepostas. Nesse primeiro experimento, foram utilizadas todas as variáveis de entrada
 263 apresentadas na Tabela 2, inclusive o consumo diário de matéria seca, para prever o ganho de
 264 peso das novilhas, totalizando 159 predições, o mesmo número de observações utilizadas no
 265 banco de dados.




266

Figura 2. Representação gráfica da predição do ganho de peso médio diário real (azul) e estimado (vermelho) pela Rede Neural Artificial (RNA).

267 Já no segundo experimento, também usando as mesmas variáveis da Tabela 2, inclusive
 268 o ganho de peso médio diário, foi realizada a predição do consumo de matéria seca. Conforme
 269 a Figura 3, da mesma forma que a anterior, o consumo real é representado pela linha azul
 270 enquanto a linha vermelha representa o consumo de matéria seca estimado pela RNA,
 271 indicando, mais uma vez, que a rede foi eficaz nessa predição.

272



273

Figura 3. Representação gráfica da predição do consumo de matéria seca real (azul) e estimado (vermelho) pela Rede Neural Artificial (RNA).

274 As predições realizadas pela rede neural artificial se assemelharam bastante ao
 275 consumo e ganho de peso real dos animais, conforme demonstrado pelas Figuras anteriores.

276 Entretanto, para corroborar sua veracidade, foram selecionadas algumas das predições e
277 representadas as médias gerais dos dois experimentos (Tabela 4).

278


279 **Tabela 4** – Média, valores reais e preditos pela rede neural artificial, de consumo de matéria seca e
280 ganho de peso médio diário, de algumas das 159 predições realizadas.

Observação	CMS, kg/dia		GMD, kg/dia	
	Real	Estimado	Real	Estimado
3	10,76	10,55	1,31	1,54
12	12,93	12,94	1,28	1,37
20	11,48	11,50	1,83	1,94
39	8,93	8,60	0,50	0,54
50	10,82	10,84	0,91	0,90
70	9,74	9,86	0,83	0,82
94	5,00	5,03	0,62	0,70
105	6,39	6,39	0,83	0,85
125	8,57	8,59	1,17	1,10
149	12,37	12,36	1,48	1,59
Média	8,33	8,34	0,93	0,98

281 *Média total das 159 previsões


282

283 Na comparação entre os valores reais de consumo de matéria seca e os estimados por
284 algumas equações, houve uma superestimação do consumo pela equação do NRC (2016), uma
285 vez que o consumo real dos animais foi inferior ao estimado (Figura 4). Por outro lado, a
286 equação do NRC (2021) subestimou os valores, apresentando um consumo estimado menor
287 que o real (Figura 5).



288


Figura 4. Comparação do consumo de matéria seca real (azul) com o predito pela equação do NRC (2016) para novilhas de corte, representado pela cor vermelha.



289

Figura 5. Comparação do consumo de matéria seca real (azul) com o predito pela equação do NRC (2021) para novilhas leiteiras, representado pela cor vermelha.

290 E por fim, a comparação entre o consumo de matéria seca real, o predito pela Rede
 291 neural artificial e pelas duas equações publicadas (NRC 2016 e 2021) mostram que a predição
 292 que mais se assemelhou ao real foi a feita pela RNA (Figura 6). O erro médio quadrático
 293 também exemplifica isso, já que o menor erro foi apresentado pela RNA, mostrando sua alta
 294 precisão (Tabela 5).



295

Figura 6. Comparação do consumo de matéria seca estimado pela RNA com as equações do NRC (2016) e NRC (2020) para novilhas.

296

Tabela 5 – Resultados do erro médio quadrático da Rede neural artificial e das equações de consumo de matéria seca usadas para comparação.

297

	Erro Médio Quadrático
NRC 2016	3,7809
NRC 2021	2,7642
RNA	0,2555

298

299 **4.4 Discussão**

300

A elevada variação no consumo de matéria seca, tanto em kg/dia como em porcentagem do peso corporal, ocorreu devido ao peso corporal das novilhas, que variou de 80 a 457 kg, tendo, dessa forma, animais com maior capacidade de trato gastrointestinal para consumo de alimentos, além de possuírem maiores exigências nutricionais. Essa variação também determinou a diferença em todos os outros consumos de nutrientes, pois eles compõem a matéria seca e a sua ingestão determina o suprimento nutricional, que deve ser em quantidades suficientes para atender às necessidades de manutenção e produção dos animais (NRC, 2001).

308

Como observado, a rede neural artificial apresentou resultados de forma diferente dos que habitualmente são vistos na literatura, ao invés de gerar equações complexas que posteriormente seriam utilizadas para calcular o consumo a partir de dados específicos dos

310

311 animais ou da dieta. Esse método realizou as previsões diretamente, criando um modelo que
312 relacionou diferentes variáveis, como idade, consumo de nutrientes, peso corporal,
313 composição corporal, entre outras, com o consumo de matéria seca e ganho de peso das
314 novilhas.

315 Este modelo pode ser treinado usando dados históricos de estudos já realizados, em
316 que as variáveis de entrada são as informações disponíveis sobre as novilhas e a variável de
317 saída é o consumo de matéria seca ou ganho em peso. Isso ocorre porque as RNA's possuem
318 a capacidade de aprendizagem através de exemplos (variáveis de entrada) fornecendo
319 respostas coerentes para dados até então desconhecidos, demonstrando a capacidade da
320 rede de extrair informações não apresentadas de forma explícita através dos exemplos (Braga
321 et al., 2000; Silva et al., 2017).

322 Os trabalhos encontrados, semelhantes ao realizado neste estudo, apresentam o
323 desenvolvimento de novas equações ou ainda testes com as equações já existentes, para
324 comprovar sua precisão. Oliveira & Ferreira (2016) desenvolveram modelos de predição de
325 CMS para novilhas (78% mestiças e 22% puras holandesas) em condições tropicais. Entretanto,
326 diferente desse estudo, geraram equações não lineares (NLMIXED de Littell et al., 2006) e
327 lineares (linear misto de St Pierre, 2001), assim como a maioria dos estudos nessa área, além
328 de comparar com os 4 modelos mais utilizados (Quigley; NRC; e 2 modelos Hoffman) através
329 de variáveis de PC e GMD, também usadas nesse estudo, mas com acréscimo da variável raça.
330 De acordo com eles, apenas as equações dos modelos propostos no estudo, o modelo
331 exponencial de Hoffman I (PC como entrada) e o modelo de Quigley foram adequados.

332 Por sua vez, Busanello et al. (2021) utilizaram dados atualizados de novilhas mestiças
333 (Holandês × Gir, Holandês × Boran e outros Holandês × Zebu) manejadas em clima tropical
334 para avaliar a aptidão das equações de CMS já publicadas (Quigley et al., 1986; Stallings et al.,
335 1985; NRC, 2001; 2 modelos Hoffman et al., 2008; e 2 modelos Oliveira & Ferreira, 2016) e
336 verificaram que o modelo mais adequado foi o de Stallings et al. (1985), pois apresentou
337 menores valores na decomposição do erro (viés de média e viés de inclinação) tendo maior
338 precisão. No entanto, os autores ressaltaram que equações baseadas especialmente em
339 aprendizado de máquina com grandes conjuntos de dados podem melhorar o poder preditivo
340 dos modelos (Busanello et al., 2021).

341 A importância da criação de novilhas leiteiras decorre do alto custo de criação dos
342 animais de reposição e pelo impacto que o período de crescimento tem na produção de leite

343 ao longo da vida desses animais, ressaltando a relevância da predição precisa das necessidades
344 nutricionais das novilhas (NRC, 2001), especialmente através do CMS. O principal objetivo é
345 obter ganho de peso suficiente para alcançar o peso de cobertura o mais cedo possível, de 55
346 a 60% do PCM na inseminação (Van Amburgh et al., 2019) e, conseqüentemente, atingir a
347 idade ao primeiro parto o quanto antes, com média entre 24 e 30 meses (NRC, 2001).

348 Os volumosos utilizados nos experimentos que constituíram o banco de dados,
349 incluindo o sorgo forrageiro Volumax e o biomassa BRS 716; o capim-elefante-BRS-Capiaçu; o
350 milho e a palma forrageira, são alimentos característicos da região semiárida e adaptados às
351 condições de clima quente e seco particulares da região. São culturas que apresentam bom
352 potencial produtivo, destacam-se pela alta resistência à seca e elevada produção de biomassa,
353 mesmo em condições de alta temperatura e baixa precipitação, sendo os principais recursos
354 forrageiros utilizados na alimentação animal (Sá & Silva, 2010; Santos et al., 2015).

355 Em comparação com outros métodos de previsão, as RNA's podem oferecer vantagens,
356 como a possibilidade de analisar dados complexos e não lineares, adaptar-se a variações nos
357 dados de entrada e lidar com problemas de alta dimensionalidade (Haykin, 2009; Silva et al.,
358 2017). Isso é especialmente útil, já que o uso dos modelos baseados em equações é limitado
359 devido às características específicas utilizadas no seu desenvolvimento, como condições
360 ambientais, composição nutricional das dietas, raças típicas, idades dos animais, condições de
361 manejo, histórico genético, entre outras. Por essa razão, alguns modelos desenvolvidos em
362 determinada região podem não oferecer acurácia e precisão para prever o consumo em
363 outra, com características de criação diferentes. Isso ocorre principalmente com os modelos
364 americanos, comumente adotados no Brasil, por causa das diferenças entre os sistemas de
365 criação nos dois países (Oliveira & Ferreira, 2016).

366 Outra vantagem bastante benéfica das redes neurais artificiais tem relação com o
367 treinamento da rede, pois, depois de treinada, o modelo pode ser usado para fazer as
368 predições com base em informações atualizadas sobre as novilhas. Essas previsões podem
369 auxiliar na tomada de decisão quanto à oferta alimentar adequada a longo prazo, permitindo
370 que os responsáveis pela alimentação das novilhas ajustem a quantidade de alimento
371 fornecido para garantir o ganho de peso adequado desses animais.

372 Em relação às previsões de desenvolvimento ponderal, a literatura apresenta estudos
373 que fazem predições de peso corporal, e não de ganho de peso diário das novilhas, conforme
374 realizado neste estudo. Nesse contexto, Oliveira et al. (2013) desenvolveram equações para

375 prever o peso corporal (PC) de novilhas leiteiras mestiças Holandês-Zebu usando medidas
376 biométricas (PT, AC e altura no quadril - AG) utilizando o SAS (2000; SAS Institute Inc., Cary,
377 NC) e compararam com os modelos já publicados de Heinrichs et al. (1992) e Reis et al. (2008).
378 O modelo criado pelos autores usando PT previu com precisão o PC, pois apresentou maior
379 coeficiente de correlação (R^2) (0,930), enquanto os modelos comparados não foram tão
380 precisos, Heinrichs (0,845) e Reis (0,708).

381 Diferentemente dos trabalhos citados, que utilizam o coeficiente de determinação (R^2)
382 para mostrar a confiabilidade das equações propostas, a acurácia do modelo proposto pela
383 rede neural foi medida pelo erro médio quadrático (EQM), pela diferença média entre os
384 valores preditos e os valores reais. Os erros obtidos nos dois experimentos (consumo de
385 matéria seca e ganho de peso médio diário) foram baixos, o que mostra a capacidade de
386 aprendizagem e previsão da rede neural artificial. De acordo com Haykin (2009), o erro
387 quadrático médio é considerado uma medida de desempenho do sistema e seu valor pode
388 interromper prematuramente o processo de aprendizagem ou fazer com que a rede neural
389 perca sua capacidade de generalização, de forma que ela será considerada completamente
390 treinada (ajustada) quando o erro quadrático médio entre duas interações sucessivas for
391 menor que a precisão.

392 Poucos trabalhos publicados empregaram redes neurais em estudos com bovinos
393 leiteiros, especialmente nessa área de predições. Dohmen et al. (2021) utilizaram redes
394 neurais, porém, do tipo convolucionais (CNN) e, através de imagens de vista superior e lateral
395 e dados de peso corporal, desenvolveram um novo modelo de predição de massa corporal
396 para novilhas com até 1 ano de idade, das raças Holandesas, Montbeliarde e Sueca Vermelha.
397 Esses autores encontraram um valor de R^2 de 0,96 e um erro médio quadrático de 20 kg,
398 demonstrando que o modelo proposto foi preciso e que é possível desenvolver modelos de
399 previsão de alto desempenho com imagens 2D de animais.

400 Shadpour et al. (2022) usaram a mesma rede neural desse estudo (*Feed-forward*
401 *Perceptron*); entretanto, para vacas leiteiras de raça Holandesa, para avaliar se a inclusão de
402 dados NIRS (Espectroscopia de Infravermelho) do leite poderiam melhorar as previsões de
403 CMS. A predição foi realizada combinando dados de parto, consumo, produção e composição
404 do leite, peso, lactações, país e rebanho. A inclusão de dados do NIRS melhorou a previsão do
405 CMS, porém, essa previsão ocorreu por meio da sua associação com características de

406 produção de leite, e sua utilidade para estimar a eficiência alimentar, como consumo residual
407 de ração, pode ser limitada e necessita de mais investigação.

408 Cada equação de predição desenvolvida estima o consumo de matéria seca, dando
409 ênfase a diferentes variáveis que podem influenciar o potencial de consumo pelos animais. A
410 equação determinada pelo NRC (2021) utiliza a equação de Hoffman et al. (2008) para novilhas
411 holandesas, apenas com a inclusão da variável PCM (peso corporal maduro) para possibilitar
412 sua utilização em todas as raças. Por outro lado, a equação do NRC (2016) ainda é a mesma
413 proposta pelo NRC (2000) e utiliza as variáveis peso corporal metabólico ($PC^{0,75}$) e energia
414 líquida de manutenção (EL_m). Dessa forma, a diferença nas variáveis utilizadas nas equações pode
415 determinar a sub ou superestimação do consumo real.

416 O NRC (2000) já considerava que os métodos descritos para predizer o consumo de
417 matéria seca são planejados para fornecer orientação geral e que não existe equação capaz de
418 ser aplicada em todas as situações de produção. Portanto, o indicado seria desenvolver
419 modelos de predição do CMS específicos para determinado sistema de criação. Assim, tais
420 modelos seriam capazes de explicar maior porcentagem da variação observada no CMS.

421 Na comparação geral da predição do consumo de matéria seca pelas equações do NRC
422 (2016) e NRC (2021) com o consumo real e o predito pela rede neural artificial, é possível
423 compreender a capacidade da rede neural de realizar predições bem similares ao real
424 consumo dos animais, possivelmente devido ao banco de dados utilizado, que compreendeu
425 diversas variáveis, enquanto as equações são limitadas a uma ou duas variáveis apenas.

426

427 **4.5 Conclusão**

428 A rede neural foi eficiente na predição do consumo de matéria seca e na predição do
429 ganho de peso médio diário das novilhas leiteiras mestiças em regiões semiáridas.

430

431 **AGRADECIMENTOS**

432 Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de Minas Gerais
433 (FAPEMIG) pelo apoio financeiro da pesquisa; à Unimontes; ao Instituto Nacional de Ciência e
434 Tecnologia (INCT); e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico
435 (CNPq), pelo auxílio com bolsas de estudo. Este estudo foi financiado em parte pela
436 Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código
437 Financeiro 001.

438 **4.7 Referências bibliográficas**

- 439
- 440 Braga, A. de P., Ludemir, T.B., Carvalho, A.C.P. de L.F., 2000. Redes neurais artificiais. Teorias e
441 aplicações, 1st ed. Livros Técnicos e Científicos Editora S.A., Rio de Janeiro.
- 442 Busanello, M., Sousa, D.G. de, Mendonça, F.A.C., Daley, V.L., Almeida, R. de, Bittar, C.M.M., Lanna,
443 D.P.D., 2021. Feed intake of growing dairy heifers raised under tropical conditions: A model
444 evaluation using meta-analysis. *Animals* 11, 3181. <https://doi.org/10.3390/ani11113181>
- 445 Dohmen, R., Catal, C., Liu, Q., 2021. Image-based body mass prediction of heifers using deep neural
446 networks. *Biosyst Eng* 204, 283–293. <https://doi.org/10.1016/j.biosystemseng.2021.02.001>
- 447 Dumas, A., Dijkstra, J., France, J., 2008. Mathematical modelling in animal nutrition: A centenary
448 review. *Journal of Agricultural Science* 146, 123–142.
449 <https://doi.org/10.1017/S0021859608007703>
- 450 Ferreira, D. F. (2008). SISVAR: um programa para análises e ensino de estatística. In *Revista*
451 *symposium*, 6(2), 36-41.
- 452 Haykin, S., 2009. *Neural Networks and Learning Machines*, 3rd ed. Pearson Education, New Jersey.
453 https://doi.org/10.1007/978-3-030-44146-3_14
- 454 Haykin, S., 2001. Kalman filters. *Kalman filtering and neurais networks*, 1-21.
455 <https://doi.org/10.1002/0471221546.ch1>
- 456 Haykin, S., 1999. *Neural networks: A comprehensive foundation*, 2 ed. ed, Prentice Hall International.
457 Tom Robbins, Ontario, Canadá. [https://doi.org/10.1016/0967-0661\(95\)90080-2](https://doi.org/10.1016/0967-0661(95)90080-2)
- 458 Heinrichs, A.J., Rogers, G.W., Cooper, J.B., 1992. Predicting Body Weight and Wither Height in
459 Holstein Heifers Using Body Measurements. *J Dairy Sci* 75, 3576–3581.
460 [https://doi.org/10.3168/jds.S0022-0302\(92\)78134-X](https://doi.org/10.3168/jds.S0022-0302(92)78134-X)
- 461 Heinrichs, A.J., Erb, H.N., Rogers, G.W., Cooper, J.B., Jones, C.M., 2007. Variability in Holstein heifer
462 heart-girth measurements and comparison of prediction equations for live weight. *Prev Vet*
463 *Med* 78, 333–338. <https://doi.org/10.1016/j.prevetmed.2006.11.002>
- 464 Hoffman, P.C., Weigel, K.A., Wernberg, R.M., 2008. Evaluation of equations to predict dry matter
465 intake of dairy heifers. *J Dairy Sci* 91, 3699–3709. <https://doi.org/10.3168/jds.2007-0644>
- 466 Hurst, T.S., Lopez-Villalobos, N., Boerman, J.P., 2021. Predictive equations for early-life indicators of
467 future body weight in Holstein dairy heifers. *J Dairy Sci* 104, 736–749.
468 <https://doi.org/10.3168/jds.2020-18560>
- 469 Köppen, W. (1948). *Climatologia: con un estudio de los climas de la terra*. México. Fondo de Cultura
470 Económica. 479p.
- 471 NRC, 2021. *Nutrient Requirements of Dairy Cattle*, 8th revise. ed. National Academies Press,
472 Washington D.C.
- 473 NRC, 2016. *Nutrient Requirements of Beef Cattle*, 8th ed. National Academies Press, Washington D.C.
474 <https://doi.org/10.17226/19014>
- 475 NRC, 2001. *Nutrient Requirements of Dairy Cattle*, 7th ed. National Academy Press, Washington D.C.
- 476 NRC, 2000. *Nutrient Requirements of Beef Cattle*, 7th ed. National Academies Press, Washington D.C.
- 477 Oliveira, A.S., Abreu, D.C., Fonseca, M.A., Antoniassi, P.M.B., 2013. Short communication:
478 Development and evaluation of predictive models of body weight for crossbred Holstein-Zebu
479 dairy heifers. *J Dairy Sci* 96, 6697–6702. <https://doi.org/10.3168/jds.2013-6988>
- 480 Oliveira, A.S., Ferreira, V.B., 2016. Prediction of intake in growing dairy heifers under tropical
481 conditions. *J Dairy Sci* 99, 1103–1110. <https://doi.org/10.3168/jds.2015-9638>
- 482 Prechelt, L. (1994). *Proben1: A set of neural network benchmark problems and benchmarking rules*.
- 483 Quigley, J.D., James, R.E., McGilliard, M.L., 1986. Dry Matter Intake in Dairy Heifers. 2. Equations to
484 Predict Intake of Heifers under Intensive Management. *J Dairy Sci* 69, 2863–2867.
485 [https://doi.org/10.3168/jds.S0022-0302\(86\)80740-8](https://doi.org/10.3168/jds.S0022-0302(86)80740-8)
- 486 Reis, G.L., Albuquerque, F.H.M.A.R., Valente, B.D., Martins, G.A., Teodoro, R.L., Ferreira, M.B.D.,
487 Monteiro, J.B.N., Almeida e Silva, M. de, Madalena, F.E., 2008. Predição do peso vivo a partir de
488 medidas corporais em animais mestiços Holandês/Gir. *Ciência Rural* 38, 778–783.
489 <https://doi.org/10.1590/S0103-84782008000300029>

490 Rumelhart, D.E., Hintont, G.E., Williams, R.J., 1986. Learning representations by Back-Propagating
491 errors. *Nature* 323, 533–536. <https://doi.org/https://doi.org/10.1038/323533a0>

492 Sá, I.B., Silva, P.C.G. da, 2010. *Semiárido Brasileiro: pesquisa, desenvolvimento e inovação*, Embrapa
493 Semiárido. Embrapa Semiárido, Petrolina.

494 Santos, P.M., Vinholis, M. de M.B., Dias-Filho, M.B., Voltolini, T.V., Mittelmann, A., Pezzopane, J.R.M.,
495 Evangelista, S.R.M., Moura, M.S.B. de, Gomide, C.A. de M., Cavalcante, A.C.R., Corrêa, C.G.,
496 Bettiol, G.M., Santos, R.M., Angelotti, F., Oliveira, P.P.A., Souza, F.H., Almeida, I.R. de, Bosi, C.,
497 Cruz, P.G. da, Andrade, A.S., Araujo, L.C. de, Pellegrino, G.Q., 2015. *Produção animal no Brasil:*
498 *caracterização, simulação de cenários para pastagens e alternativas de adaptação às mudanças*
499 *climáticas*, 1st ed. Embrapa Pecuária Sudeste, São Carlos.

500 Shadpour, S., Chud, T.C.S., Hailemariam, D., Oliveira, H.R., Plastow, G., Stothard, P., Lassen, J.,
501 Baldwin, R., Miglior, F., Baes, C.F., Tulpan, D., Schenkel, F.S., 2022. Predicting dry matter intake
502 in Canadian Holstein dairy cattle using milk mid-infrared reflectance spectroscopy and other
503 commonly available predictors via artificial neural networks. *J Dairy Sci* 105, 8257–8271.
504 <https://doi.org/10.3168/jds.2021-21297>

505 Silva, I.N. da, Spatti, D.H., Flauzino, R.A., Liboni, L.H.B., Alves, S.F. dos R., 2017. *Artificial Neural*
506 *Networks*, 1st ed. Springer. https://doi.org/10.1007/978-1-4939-2239_0

507 Soberon, F., Raffrenato, E., Everett, R.W., Van Amburgh, M.E., 2012. Preweaning milk replacer intake
508 and effects on long-term productivity of dairy calves. *J Dairy Sci* 95, 783–793.
509 <https://doi.org/10.3168/jds.2011-4391>

510 Souza, M.C., Oliveira, A.S., Araújo, C. V., Brito, A.F., Teixeira, R.M.A., Moares, E.H.B.K., Moura, D.C.,
511 2014. Short communication: Prediction of intake in dairy cows under tropical conditions. *J Dairy*
512 *Sci* 97, 3845–3854. <https://doi.org/10.3168/jds.2013-7652>

513 Stallings, C.C.; Kroll, G.; Kelley, J.C.; McGilliard, M.L. 1885. A computer ration evaluation program for
514 heifers, dry cows, and lactating cows. *J Dairy Sci* 68, 1015–1019.
515 [https://doi.org/10.3168/jds.S0022-0302\(85\)80923-1](https://doi.org/10.3168/jds.S0022-0302(85)80923-1)

516 Van Amburgh, M.E., Soberon, F., Meyer, M.J., Molano, R.A., 2019. Symposium review: Integration of
517 postweaning nutrient requirements and supply with composition of growth and mammary
518 development in modern dairy heifers. *J Dairy Sci* 102, 3692–3705.
519 <https://doi.org/10.3168/jds.2018-15270>

520 Widrow, B., 1960. Adaptive Sampled-data Systems, in: *Proceedings of the First International*
521 *Congress of the International Federation of Automatic Control*. pp. 406–411.

522 Widrow, Bernard, 1960. An Adaptive “Adaline” Neuron Using Chemical “Memistors.” Stanford
523 Electronics Laboratories Technical Report.

524 Widrow, B., Hoff, M.E., 1960. Adaptive switching circuits. *IRE WESCON Convention Record* 4, 96–
525 104.

526
527
528
529
530
531
532
533
534
535
536
537
538

539 **CONSIDERAÇÕES FINAIS**

540 O método de redes neurais é eficiente na predição de ganho de peso e consumo de
541 alimentos, e torna-se uma ferramenta de auxílio na criação das novilhas. Sua utilização pode
542 proporcionar melhorias ao acompanhar o desenvolvimento dos animais, auxiliando na
543 manutenção de um adequado crescimento, de forma que as novilhas atinjam peso suficiente
544 à primeira inseminação e, conseqüentemente, peso ao primeiro parto o mais cedo possível.
545 Dessa forma, elas irão começar sua vida produtiva o quanto antes e serão inseridas no
546 rebanho como substitutas dos animais descartados, como é o objetivo da sua criação.