

Inteligência Computacional para Estimação dos Requerimentos Energéticos em Gado Bovino

Robson Rosserrani de Lima^{1a}, Danton Diego Ferreira^{1b} e Mateus Pies Gionbelli²

¹ Departamento de Engenharia, Universidade Federal de Lavras, Lavras, MG, Brasil

² Departamento de Zootecnia, Universidade Federal de Lavras, Lavras, MG, Brasil
robson_rosserrani@posgrad.ufla.br^{1a}, danton@deg.ufla.br^{1b},
mateus.pg@dzo.ufla.br²

Resumo. Este trabalho propõe a utilização de técnicas computacionais baseadas em Inteligência Computacional (IC) para a estimação dos requerimentos energéticos em gado bovino. As técnicas abordadas são: Redes Neurais Perceptron Multicamadas (MLP) e Sistemas de Inferência Neuro-Fuzzy Adaptativos (ANFIS). Ambas técnicas foram utilizadas para a estimação da Energia Metabolizável Ingerida (MEI) a partir de um banco de dados de 840 animais. Os parâmetros utilizados para a modelagem foram: gênero, raça, sistema de alimentação, peso corporal vazio médio (AEBW) e ganho de corpo vazio (EBG). Para os modelos MLP foram utilizadas arquiteturas contendo uma ou duas camadas escondidas com um número máximo de neurônios em cada camada de 10. Para a elaboração dos modelos ANFIS, foram utilizadas duas técnicas de clusterização, Fuzzy C-Means (ANFIS-FCM) e Clusterização Subtrativa (ANFIS-SC), que foram responsáveis pela geração do Sistema de Inferência Fuzzy (FIS) inicial, posteriormente reestruturado para a arquitetura ANFIS. Os modelos MLP obtiveram correlação média superior a 80%, enquanto os modelos ANFIS obtiveram resultados da ordem de 74%. A técnica MLP supera a abordagem clássica para a estimação da MEI, baseada em regressão linear múltipla (MLR). As técnicas de IC se mostraram promissoras e boas alternativas aos modelos comumente usados.

Palavras-chave: Inteligência Computacional, Requerimentos Energéticos, MLP, ANFIS.

1 Introdução

O Brasil é o segundo maior exportador de carne bovina do mundo, estando apenas atrás da Índia. No ano de 2015 foram abatidas 33,9 milhões de cabeças de gado bovino em todo país, nesse mesmo ano a arroba do boi gordo estava sendo comercializada a R\$ 143,60 e foram consumidas, somente no território nacional, 7188 mil toneladas. Dados do Ministério da Agricultura, Pecuária e Abastecimento (MAPA), apontam ainda para o período de 2015/25 um aumento na produção de 23,3%, do consumo de 17,8% e das exportações em 37,4% [1].

Para comportar esse crescimento, o setor enfrenta vários desafios, tanto ambientais, como o aumento da produção sem oferecer riscos aos biomas nativos devido ao aumento da área de manejo e resíduos, quanto econômicos, como diminuir os gastos com o manejo. Os maiores custos associados à atividade, hoje, dizem respeito a gastos com alimentação. Um caminho que pode contribuir para solução desses desafios é o aumento da eficiência energética dos animais, isto é, a formulação de dietas que, com uma mesma unidade de alimento, consigam produzir um ganho de peso maior e com menos resíduos.

As dietas são formuladas com base na estimação dos requerimentos energéticos do gado, mais especificamente na estimação da Energia Metabolizável Ingerida (MEI), calculada através de regressão linear múltipla (MLR). Entretanto a técnica oferece limitações quanto ao número de parâmetros abordados e quanto ao tempo para a formulação dos modelos. Técnicas de Inteligência Computacional (IC) como Redes Neurais Artificiais (RNA) e Sistemas de Inferência Neuro-Fuzzy Adaptativos (ANFIS) podem superar essas limitações uma vez que possuem ótima capacidade de aprendizagem.

As técnicas de IC vem sendo amplamente utilizadas no campo da Hidrologia para predição de transporte e acumulação de sedimentos, evaporação, evapotranspiração, chuva e escoamento de superfície e bacias hidrográficas [2-11]. Dentro das Ciências Animais, têm sido utilizadas principalmente para solução de problemas envolvendo predição de séries temporais e agrupamento de dados [12]. Uma busca em bancos de periódicos revela que os campos de pesquisa com maior aplicação da Teoria Fuzzy e de RNA são os de previsão de crescimento animal [13-16], lactação de bovinos e caprinos [17-19], conforto térmico e zoneamento bioclimático [20,21], reprodução de bovinos [22, 23], sustentabilidade do manejo [24], desenvolvimento de parasitas [25], estimação de concentração de nutrientes [26], previsão de valores genéticos [27, 28] e produção de ovos [29]. No entanto existe apenas um estudo disponível para predição de requerimentos energéticos em bovinos usando RNA [30]. Em todas as aplicações as técnicas baseadas em IC superaram os métodos tradicionais ou se equipararam a eles, mostrando o grande potencial que elas oferecem para as ciências animais.

Dado o bom desempenho das técnicas em outros campos de pesquisa, esse trabalho propõe a utilização de Inteligência Computacional como uma alternativa a abordagem clássica para a estimação da MEI. São propostos o uso de Redes Neurais Perceptron Multicamadas (MLP) e Sistemas de Inferência Neuro-Fuzzy Adaptativos (ANFIS). Todos os modelos foram estimados utilizando o mesmo banco de dados e levaram em consideração gênero, raça, sistema de alimentação, peso corporal vazio médio (AEBW) e ganho de corpo vazio (EBG).

A próxima Seção apresenta a metodologia utilizada. Na Seção 3 são apresentados os resultados e discussões. Na Seção final são feitas as conclusões e propostas para futuros trabalhos.

2 Metodologia

2.1 Banco de Dados

Foi utilizado uma porção do conjunto de dados do Sistema BR-CORTE [31] para elaboração e comparação dos modelos. O banco de dados utilizado nesse trabalho contém dados de 31 experimentos comparativos de abate, com informações individuais de 840 animais. O conjunto de dados foi composto por 558 touros, 175 novilhos e 107 novilhas, 544 Zebu de raça pura e 296 mestiços e 672 animais de confinamento e 168 de pastagem. O peso corporal vazio (EBW, na sigla em inglês) variou de 94 a 506 kg.

Foram considerados efeitos de gênero (macho, castrado ou fêmea), raça (Zebu de raça pura ou mestiços), sistema de alimentação (pastagem ou confinamento), bem como as informações de Peso de Corpo Vazio Médio (AEBW, na sigla em inglês) e Ganho de Corpo Vazio (EBG, na sigla em inglês), disponíveis no banco de dados, totalizando cinco parâmetros de estudo.

A fim de se investigar o número de dados nas estimações, o conjunto de dados foi dividido aleatoriamente em dois subconjuntos, treinamento e validação. Esses subconjuntos, por sua vez, tiveram diferentes tamanhos variando-se a porcentagem de animais considerados dentro do intervalo de 10 a 90% do conjunto total, sendo um subconjunto o complemento do outro, assim, por exemplo, quando o conjunto de treinamento contém 60% dos dados ($n = 504$ animais) o conjunto de validação contém 40% ($n = 336$ animais). Foram criados, portanto, nove conjuntos de treinamento e nove conjuntos de validação, seguindo o critério descrito acima.

2.2 Pré-Processamento

Antes de serem apresentados aos regressores, os vetores de parâmetros considerados foram normalizados de acordo com a seguinte regra:

$$\mathbf{x}_n = \mathbf{x} / \max(\text{abs}(\mathbf{x})) \quad (1)$$

onde \mathbf{x} é o vetor de parâmetros original e \mathbf{x}_n é sua versão normalizada. A função 'abs(\mathbf{x})' retorna os valores absolutos de cada elemento de um vetor ou matriz \mathbf{x} e a função 'max(\mathbf{x})' retorna o valor máximo da matriz usada como argumento.

2.3 Técnicas Propostas

Foram propostas duas diferentes técnicas, todas implementadas via software MatLab. Para cada uma, cada modelo proposto foi simulado 100 vezes e calculou-se o valor médio do desempenho e o desvio padrão. Também foi realizado um teste de Comparação Múltipla de Médias, também chamado de Teste de Tukey, com significância de 0,05.

As características dos modelos são brevemente discutidas a seguir.

Redes Neurais Perceptron Multicamadas (MLP). O MLP consiste em uma série de camadas de neurônios (cada neurônio implementa um perceptron) [32]. A primeira camada tem conexão com a entrada da rede. Cada camada subsequente tem conexão com a camada anterior. A camada final produz a saída da rede.

Redes MLP podem ser usadas para qualquer tipo de mapeamento entrada/saída. Uma rede com uma camada escondida e um número suficiente de neurônios pode resolver qualquer problema de mapeamento entrada/saída finito [32]. Porém, uma rede com uma camada escondida muito grande pode diminuir o desempenho computacional do método, assim uma segunda camada escondida pode apresentar uma melhor alternativa. A Figura 1 mostra a arquitetura geral de uma rede MLP.




Fig. 1. Arquitetura geral de uma rede MLP com duas camadas escondidas.

O vetor \mathbf{x} com R parâmetros é apresentado a primeira camada da rede multiplicado pelos pesos sinápticos \mathbf{w}_1 . Na primeira camada, também chamada de Primeira Camada Escondida, com S_1 neurônios, é feita a soma desses valores a um valor de polarização \mathbf{b}_1 , que após aplicada a função de ativação \mathbf{f}_1 a saída da primeira camada, \mathbf{y}_1 , é gerada. O processo é repetido por todas as camadas de forma análoga, até gerar a saída da rede, na Figura 1, a terceira camada ou camada de saída.

As redes MLP implementadas nesse trabalho possuem arquitetura com uma ou duas camadas escondidas e um neurônio de saída. O número de neurônios presentes na primeira camada intermediária foi variado no intervalo 1-10, sendo acrescentado iterativamente um neurônio por vez. Para a segunda camada intermediária, a quantidade de neurônios foi variada no intervalo 0-10. Criou-se um sistema iterativo para construção dos modelos de forma que antes de se acrescentar um neurônio na primeira camada, acrescentava-se os neurônios da segunda camada intermediária, gerando um total de 110 modelos, no que diz respeito ao número de neurônios. Cada um desses 110 modelos foi treinado e validado utilizando os subconjuntos de treinamento e teste citados na Subseção 2.1.

Utilizou-se o algoritmo *Scaled Conjugate Gradient Backpropagation* [33] para o treinamento, a função tangente hiperbólica como função de ativação nas camadas

intermediárias, para o neurônio de saída utilizou-se a função linear como ativação. Essas funções são definidas respectivamente como:

$$y = \text{tansig}(x) = \frac{2}{1 + \exp(-2x)} - 1 \quad (2)$$

$$y = \text{purelin}(x) = x \quad (3)$$

Sistemas de Inferência Neuro-Fuzzy Adaptativos. Os Sistemas de Inferência Fuzzy (FIS) podem descrever fenômenos complexos e não-lineares com regras precisas [5, 7]. O modelo Fuzzy, que se baseia na Lógica Fuzzy, primeiramente introduzido por Zadeh [11] como uma ferramenta matemática para construir a Lógica Fuzzy de um sistema que funciona aplicando-se regras de aprendizagem neural para identificar a estrutura do FIS. É uma técnica poderosa de design que serve como base para se construir regras Fuzzy “se-então” ou declarações condicionais Fuzzy da forma “se A então B”. Nessa declaração, A e B representam conjuntos Fuzzy caracterizados por Funções de pertinência (MF). Takagi e Sugeno [10] conduziram um estudo sistemático de modelagem Fuzzy para identificar a estrutura dos FIS e melhoram a implicação Fuzzy reduzindo o número de implicações e simplificando o raciocínio.

Após estudos anteriores em Lógica Fuzzy, Jang [6] desenvolveu uma arquitetura e procedimento de aprendizado para transformar conhecimento ou experiência humana em Sistemas de Inferência Fuzzy e chamou essa técnica de Sistemas de Inferência Neuro-Fuzzy Adaptativos (ANFIS). ANFIS utiliza algoritmos de aprendizagem de RNA e raciocínio Fuzzy para empregar regras “se-então”. O modelo minimiza a soma dos quadrados dos erros entre o desejado e a saída atual.

O algoritmo ANFIS foi usado para construir um modelo Fuzzy de um sistema para prever dados desconhecidos. A Figura 2 apresenta a arquitetura típica de um modelo ANFIS com duas entradas com nós fixos (círculos) e nós adaptativos (retângulos). A figura contém os nós de entrada (camada 1), as camadas escondidas (camadas 2, 3 e 4) e um único nó de saída (camada 5).

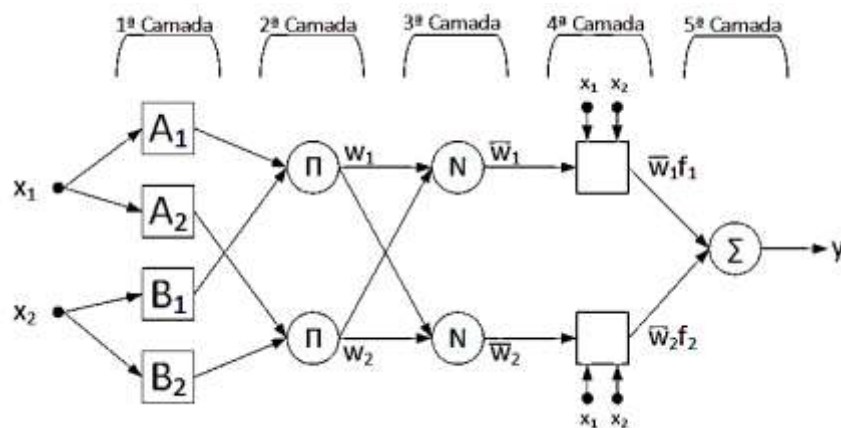


Fig. 2. Arquitetura típica de um ANFIS com duas entradas.

Os nós nas camadas escondidas funcionam como MFs e regras. A camada 1 conhecida como antecedentes dos parâmetros contém duas MFs associadas a cada parâmetro de entrada. Cada subespaço na camada 1 é particionado em outros subespaços nas camadas 2 e 3. Ambas camadas são governadas por regras Fuzzy “se-então”. Finalmente, a camada 4 conhecida como consequentes dos parâmetros delimita a saída com um subespaço Fuzzy [6].

Jang [6] simplificou um conjunto de regras típico com duas regras Fuzzy “se-então”:

Regra 1: Se x é A_1 e y é B_1 , então $f_1 = p_1x + q_1y + r_1$

Regra 2: Se x é A_2 e y é B_2 , então $f_2 = p_2x + q_2y + r_2$

Onde x e y são duas variáveis de entrada, A e B denotam os termos linguísticos da função do nó e p , q e r são os parâmetros consequentes. Os detalhes e fundo matemático do ANFIS e a descrição detalhada de cada camada na Figura 1 são encontrados em [6, 34].

Neste estudo, dois tipos de ANFIS, baseados em Clusterização Fuzzy C-Means (ANFIS-FCM) e Clusterização Subtrativa (ANFIS-SC) foram utilizados para estimar a Energia Metabolizável Ingerida em bovinos de corte.

O ANFIS-FCM utilizado nesse estudo utiliza duas diferentes funções de pertinência (MF): gaussiana para as MFs de entrada e linear para as MFs de saída. Foram utilizados 15 clusters para dividir os dados, com uma matriz de partição com ordem dois, que identifica o nível de sobreposição dos clusters. O algoritmo utilizou 200 iterações e um limiar de melhoria de 10^{-5} como critérios de parada. O algoritmo foi simulado pelo software MatLab, que gera uma regra para cada cluster.

O modelo ANFIS-SC pode ser utilizado quando não se tem ideia do número de clusters, o algoritmo cria iterativamente novos clusters, baseados nos seus raios de influência e na densidade de dados em torno de um possível centro de cluster. Utilizou-se o valor de 0,3 como raio de influência dos clusters. Foram também utilizadas como MFs as funções gaussiana e linear para a entrada e saída, respectivamente, e foi gerada uma regra para cada cluster.

Os processos de treinamento e validação foram feitos para ambos modelos com 5 parâmetros de entrada. O algoritmo de treinamento foi um modelo híbrido entre a técnica “Backpropagation” e Mínimos Quadrados. Cada modelo foi gerado 100 vezes e calculou-se o valor médio do desempenho e o desvio padrão. Também foi realizado um Teste de Comparação Múltipla de Médias, também chamado Teste de Tukey, com significância de 0,05.

3 Resultados e Discussões

3.1 Perceptron Multicamadas (MLP)

Buscou-se avaliar a influência do número de dados utilizados para o treinamento das Redes MLP, para tanto, o conjunto de dados foi dividido em nove subconjuntos, com

10% a 90% dos dados totais, 840 animais, utilizados para treinamento, utilizando o restante dos dados (90% a 10%) para a validação das redes.

A Figura 3 apresenta o desempenho encontrado para os testes supracitados. Os valores dizem respeito à correlação média das 100 execuções de cada modelo. No eixo abscissas estão os índices de cada modelo, organizados de forma que os modelos 1, 12, 23, etc., correspondam aos modelos com apenas uma camada escondida, com o número de neurônios nessa camada sendo acrescido de um em um. Os modelos dentro dos intervalos]1, 12[,]12, 23[, etc., correspondem àqueles com duas camadas escondidas, se mantém o número de neurônios na primeira camada constante e incrementa-se o número na segunda camada.




Fig. 3. Desempenho dos modelos MLP para um vetor de entrada com 5 parâmetros e número de dados de Teste variando-se de 90% a 10%.

Podemos observar alguns comportamentos ao analisarmos o gráfico da Figura 3. Primeiramente, quanto mais dados foram utilizados para o treinamento, e consequentemente menos para teste, maior foram os desempenhos médios dos regressores. A partir de 4 neurônios na primeira camada escondida, o acréscimo de neurônios na segunda camada aumenta o desempenho para os modelos com 2 camadas escondidas, porém os picos mostrados no gráfico mostram que o desempenho médio de todos os classificadores com apenas 1 camada escondida foi superior as suas contrapartes com 2 camadas. Para esses classificadores, com 1 camada escondida, o aumento de neurônios também aumenta o desempenho.

A Figura 4 mostra o resultado do Teste de Tukey, com significância 0,05, para os modelos em relação ao número de dados utilizado para teste. O eixo das abscissas diz

respeito à correlação média de todos os modelos com uma mesma porcentagem de dados de teste independente da arquitetura. Pode-se verificar que todos os grupos têm diferença estatística significativa, uma vez que nenhum grupo se intersecta. Além disso, a correlação média de todos os grupos foi superior a 0.85




Fig. 4. Teste de Tukey dos modelos MLP para um vetor de entradas com 5 parâmetros e número de dados de teste variando-se de 90% a 10%.

3.2 Sistemas de Inferência Neuro-Fuzzy Adaptativos (ANFIS)

Para a arquitetura ANFIS foram utilizadas duas técnicas, Fuzzy C-Means e Clusterização Subtrativa. Essas técnicas tiveram como objetivo a elaboração do modelo inicial de inferência Fuzzy, que depois foi convertido em uma arquitetura ANFIS e treinada. A Figura 5 mostra o desempenho para os modelos ANFIS-SC e ANFIS-FCM para um conjunto de dados de Teste de 40% ($n = 336$ animais) do total de dados e 5 parâmetros de entrada.




Fig. 5. Desempenho dos modelos ANFIS-SC (1) e ANFIS-FCM (2) para um vetor de entrada com 5 parâmetros e número de dados de Teste igual a 40%.

A correlação média para ANFIS-SC foi de 0.6946 ± 0.1662 , enquanto para ANFIS-FCM foi de 0.7419 ± 0.1565 . Para confirmar se existe melhor desempenho real entre os dois métodos foi realizado o Teste de Tukey. A Figura 6 mostra o resultado do teste e confirma que o modelo ANFIS-FCM foi melhor que o ANFIS-SC.




Fig. 1. Resultados do Teste de Tukey para ANFIS-SC e ANFIS-FCM utilizando 40% de dados para teste e significância de 0,05.

3.3 Comparação de Desempenhos

A Tabela 1 mostra um comparativo do desempenho médio de todos os regressores propostos para um total de dados de teste igual a 40%. O resultado para a arquitetura MLP diz respeito ao resultado médio de todas as redes que utilizaram essa quantidade de dados para teste. Também se utiliza como comparativo um trabalho anterior [30] que utilizou 40% ($n = 336$ animais) dos dados para teste de seus modelos e técnicas baseadas em RNA e RLM. Esse comparativo é feito pois em [30] são utilizados o mesmo banco de dados, parâmetros e, para o caso da técnica baseada em RNA, o mesmo tipo de construção das redes.

Tabela 1. Desempenho comparativo dos métodos de estimação da MEI para 40% de dados de Teste e 5 parâmetros de entrada.

Método	Correlação Média
MLP	0.891 ± 0.004
ANFIS-SC	0.695 ± 0.166
ANFIS-FCM	0.742 ± 0.156
MLP [30]	0.888*
MLR [30]	0.794*

* Não foi fornecido o desvio padrão em [30].

A Tabela 1 mostra que os modelos baseados na arquitetura MLP tiveram os melhores resultados tanto para esse estudo quanto para o apresentado em [30], sendo capazes de superar a abordagem clássica de estimação da Energia Metabolizável Ingerida.

4 Conclusões

O trabalho apresentou duas abordagens para estimação da Energia Metabolizável Ingerida em gado bovino, que apresentaram altas taxas de correlação entre os valores estimados e os desejados.

Os regressores desenvolvidos podem ser úteis como alternativas ao método de estimação clássico que sofre limitações quanto à complexidade considerada. Além disso, o desempenho médio da técnica MLP superara o encontrado na literatura para o método clássico, evidenciando que o modelo pode inclusive vir a substituir essa metodologia.

Futuros trabalhos preveem a utilização de outras combinações de vetores de parâmetros na entrada afim de investigar o efeito do uso de cada parâmetro na estimação para os modelos ANFIS. Pretende-se também variação na quantidade de dados utilizado para treino e teste dos modelos ANFIS, uma vez que se dispõe de relativa baixa quantidade de dados para elaboração dos modelos. Por fim, espera-se ainda melhorar os modelos propostos, alterando os parâmetros utilizados para a geração da FIS inicial para o caso dos modelos ANFIS.

Agradecimentos

Os autores gostariam de agradecer à Fundação de Amparo à Pesquisa de Minas Gerais (FAPEMIG) e à Universidade Federal de Lavras (UFLA) pelo apoio a esse trabalho.

Referências

1. P. F MAPA/AGE. Projeções do agronegócio - Brasil 2014/15 a 2024/25. Ministério da Agricultura, Pecuária e Abastecimento - Assessoria de Gestão Estratégica (2015).
2. Basheer, I.A. Selection of methodology for modeling hysteresis behavior of soils using neural networks. *J. Comput. -aided Civil Infrastruct. Eng.*, 5(6), pp.445-463 (2000).
3. Cemek, B., Rahman, S., Rahman, A. Artificial neural network for predicting nutrients concentration in runoff from beef cattle feedlot. *Environmental Engineering and Management Journal*, 12(12), 2385-2396, (2013).
4. Cobaner, M. Evapotranspiration estimation by two different neuro-fuzzy inference systems. *J Hydro*, 398(3-4), pp. 292-302, (2011). doi: 10.1016/j.jhydrol.2010.12.030.
5. Ganzle, M.G., Kilimann, K.V., Hartmann, C., Vogel, R., Delgado, A. Data mining and fuzzy modelling of high pressure inactivation pathways of *Lactococcus lactis*. *Innov. FoodSci. Emerg. Technol*, 8(4), pp. 461-468, (2007). doi: 10.1016/j.ifset.2007.04.003.
6. Jang, J.S.R. ANFIS-adaptive-network-based fuzzy inference system. *IEEE Trans. Syst. Man Cyb*, 23(3), pp. 665-685, (1993). doi: 10.1109/21.256541.

7. Lertworasirikul, S. Drying kinetics of semi-finished cassava crackers: a comparative study. *LWT Food Sci. Technol.*, 41(8), pp. 1360-1371, (2008). doi: 10.1016/j.lwt.2007.09.009.
8. Paliwal, M., Kumar, U.A. Neural networks and statistical techniques: A review of applications. *Expert systems with applications*, 36(1), pp. 2-17, (2009). doi: 10.1016/j.eswa.2007.10.005.
9. Rahman, A., Rahman, S., Borhan, M.S. Performance evaluation of three vegetative filter strip designs for controlling feedlot runoff pollution. *Journal of Civil and Environmental Engineering*, 124(3), (2013). doi: 10.4172/2165-784X.1000124.
10. Takagi, T., Sugeno, M. Fuzzy identification of systems and its application to modeling and control. *IEEE Trans. Syst. Man Cyb.*, 15(1), pp. 116-132, (1985). doi: 10.1109/TSMC.1985.6313399.
11. Zadeh, L.A. Fuzzy sets. *Information and Control*, 8(3), pp. 338-353, (1965). doi: 10.1016/S0019-9958(65)90241-X.
12. Fernández, C. et al. Neural networks for animal science applications: Two case studies. *Expert Systems with Applications*, v. 31, n. 2, p. 444 – 450, (2006). ISSN 0957-4174.
13. Potokar, M.C. et al. An attempt to predict conformation and fatness in bulls by means of artificial neural networks using weight, age and breed composition information. *Italian Journal of Animal Science*, v. 14, n. 1, p. 3198, (2015).
14. Behzadi, M.R.B., Aslaminejad, A.A. A comparison of neural network and nonlinear regression predictions of sheep growth. *Journal of Animal and Veterinary Advances*, v. 9, p. 2128–2131, (2010).
15. Raja, T., Ruhil, A., Gandhi, R. Comparison of connectionist and multiple regression approaches for prediction of body weight of goats. *Neural Computing and Applications*, v. 21, n. 1, p. 119–124, fev. (2012).
16. Mottaghtalab, M. et al. Predicting caloric and feed efficiency in turkeys using the group method of data handling-type neural networks. *Poultry Science*, v. 89, n. 6, p. 1325, (2010).
17. Bhosale, M.D., Singh, T.P. Comparative study of feed-forward neuro-computing with multiple linear regression model for milk yield prediction in dairy cattle. *Current Science*, v. 108, n. 12, p. 2257, jun. (2015).
18. Grzesiak, W. et al. A comparison of neural network and multiple regression predictions for 305-day lactation yield using partial lactation records. *Canadian Journal of Animal Science*, v. 83, n. 2, p. 307–310, (2003).
19. Fernández, C. et al. Weekly milk prediction on dairy goats using neural networks. *Neural Computing and Applications*, v. 16, n. 4-5, p. 373–381, maio (2007).
20. Sousa, R.V., Canata, T.F., Leme, P.R., Martello L.S. Development and evaluation of a fuzzy logic classifier for assessing beef cattle thermal stress using weather and physiological variables. *Computers and Electronics in Agriculture*, 127, pp. 176-183, (2016). doi: 10.1016/j.compag.2016.06.014.
21. Tavares G.F., Carnevskis E.L., Schiassi L., Filho R.C., Miranda K.O.S., Miranda J.H. Bioclimatic zoning for beef cattle in Brazil with the aid of intelligent systems. *J. Anim. Behav. Biometeorol.*, 4(4), pp. 116-123, (2016). doi: 10.14269/2318-1265/jabb.v4n4p116-123.
22. Deb, R. et al. Designing of an artificial neural network model to evaluate the association of three combined y-specific microsatellite loci on the actual and predicted postthaw motility in crossbred bull semen. *Theriogenology*, v. 83, n. 9, p. 1445 – 1450, (2015). ISSN 0093-691X.
23. Shahinfar, S. et al. Prediction of breeding values for dairy cattle using artificial neural networks and neuro-fuzzy systems. *Computational and Mathematical Methods in Medicine*, v. 2012, ago. (2012).

24. Santos, S.A., et al. A fuzzy logic-based tool to assess beef cattle ranching sustainability in complex environmental systems. *Journal of Environmental Management*, 198, pp. 95-106, (2017). doi: 10.1016/j.jenvman.2017.04.076
25. Chaparroa, M.A.E., Canziani, G.A., Saumell, C.A., Fiel, C.A. Estimation of pasture infectivity according to weather conditions through a fuzzy parametrized model for the free-living stage of *Ostertagia ostertagi*. *Ecological Modelling*, 222, pp. 1820-1832, (2011).doi: 10.1016/j.ecolmodel.2011.03.019
26. Simsek, H., Cemek, B., Odabas, M.S., Rahman, S. Estimation of nutrient concentrations in runoff from beef cattle feedlot using adaptative neuro-fuzzy inference sustems. *Neural Network World*, 5(15), pp. 501-518, (2015). doi: 10.14311/NNW.2015.25.025.
27. Ehret, A. et al. Application of neural networks with back-propagation to genome-enabled prediction of complex traits in holstein-friesian and german fleckvieh cattle. *Genetics Selection Evolution*, v. 47, n. 1, p. 22, Mar (2015). ISSN 1297-9686.
28. Ventura, R. et al. Uso de redes neurais artificiais na predição de valores genéticos para peso aos 205 dias em bovinos da raça Tabapuã. *Arquivo Brasileiro de Medicina Veterinária e Zootecnia*, Scielo, v. 64, p. 411 – 418, (2012).
29. Ghazanfari, S., Nobari, K., Tahmoorespur, M. Prediction of egg production using artificial neural network. *Iranian Journal of Applied Animal Science*, v. 1, n. 1, p. 11–16, mar. (2011).
30. Gionbelli, M.P., Ferreira, D.D., Ferreira, L.K., Chizzotti, M.L., Valadares Filho, S.C. Use of artificial neural networks to improve estimation of energy requirements of cattle. *Energy and protein metabolism and nutrition*, 137, pp. 359-360, (2016).
31. Valadares Filho, S.C., Marcondes, M.I., Chizzotti, M.L. Nutrient requirements of Zebu beef cattle - BR-CORTE. 2. ed. [S.l.]: Federal Univeristy of Viçosa, Department of Animal Science, 2010. ISBN 9788590604150.
32. Theodoritis, S., Koutroumbaa, K. *Pattern Recognition*, 4 ed., Elsevier, (2009). doi:10.1016/B978-1-59749-272-0.50001-3.
33. Moller. *Neural Networks*, Vol. 6, pp. 525–533, (1993).
34. Jang, J.S.R., Sun, C.T., Mizutani, E. *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Fuzzy rules and fuzzy reasoning. 1st ed. Upper Saddle River, NJ: Prentice Hall, pp. 5-15, (1997).