



MODELO AUTOMÁTICO DE CLASSIFICAÇÃO DE BOVINOS PARA O ABATE VIA REDES NEURAIS ARTIFICIAIS

A. Bonini Neto^{1*}, C.S.B. Bonini², F.F. Putti¹, M. Campos¹,
L.R. Gabriel Filho¹, M.G.M. Chacur³, J. C. Piazzentin⁴

¹UNESP - Universidade Estadual Paulista, Faculdade de Ciências e Engenharia (FCE), Tupã, SP, Brasil

²UNESP - Universidade Estadual Paulista, Faculdade de Ciências Agrônômicas e Tecnológicas (FCAT), Dracena, SP, Brasil

³UNOESTE - Universidade do Oeste Paulista, Pró-Reitoria de Pesquisa e Pós-Graduação, Faculdade de Ciências Agrárias, Laboratório de Reprodução Animal, Presidente Prudente, SP, Brasil

⁴UNESP - Universidade Estadual Paulista, Faculdade de Ciências Agrônômicas (FCA), Botucatu, SP, Brasil

Article history: Received 24 October 2018; Received in revised form 06 December 2018; Accepted 13 December 2018; Available online 30 March 2019.

RESUMO

Hoje em dia, a busca por ferramentas que facilitam e até mesmo substituem o trabalho humano têm ganhado grande destaque mundial. As redes neurais artificiais (RNAs) é uma dessas ferramentas, pois apresentam uma quantidade de aplicações, principalmente quando se trata de classificação de dados, reconhecimento de padrões, análise de imagens, entre outros. Com este intuito, o objetivo deste trabalho foi desenvolver uma ferramenta de classificação automática de bovinos por intermédio de uma Rede Neural Artificial (RNA) de três camadas. Essa rede é conhecida como *Multilayer Perceptron* (MLP), aqui do tipo *feed forward* (sem realimentação) e com algoritmo de treinamento *backpropagation* (retropropagação do erro) com treinamento supervisionado. A ideia foi identificar os grupos de abate e os que requerem alimentação mais intensiva, utilizando como variáveis de entrada da rede massa e altura e como variável de saída, o índice de massa corporal (IMC). Os dados utilizados neste trabalho foram obtidos de um rebanho de 147 vacas Nelore, localizadas na cidade de Santa Rita do Pardo - Mato Grosso do Sul (MS). Dos resultados, a rede obteve um excelente desempenho na fase de treinamento (100 amostras), com erro quadrado médio em torno de 10^{-5} . Já na fase do diagnóstico (operação da rede), foi submetida à rede as 47 amostras restantes dos dados de vacas Nelore que não fizeram parte do treinamento da mesma, desses resultados, a rede apresentou em média, um erro em torno de 0,6% em relação à saída desejada (dados normalizados), o que acarretou num erro de 1 amostra das 47 analisadas.

Palavras-chave: Inteligência artificial; pecuária; estimativa; índice de massa corporal.

AUTOMATIC CLASSIFICATION MODEL FOR LIVESTOCK SLAUGHTERING VIA ARTIFICIAL NEURAL NETWORKS

ABSTRACT

Nowadays, the search for tools that facilitate and even replace human work have gained a great worldwide prominence. Artificial neural networks (ANNs) are one of these tools, since they present a great power of applications, especially when it comes to data classification,

* alfredo.bonini@unesp.br

pattern recognition, image analysis, among others. The objective of this work was to develop a tool for automatic classification of ruminant animals by means of an Artificial Neural Network (ANN) of three layers. This network is known as Multilayer Perceptron (MLP), here feed forward type (no feedback) and backpropagation training algorithm with supervised training. The idea was to identify the slaughter groups and those that require more intensive feeding, using as input variables the mass and height and as output variable, body mass index (BMI). The data used in this study were obtained from a herd of 147 Nelore cows, located in the city of Santa Rita do Pardo - Mato Grosso do Sul (MS). From the results, the network obtained an excellent performance in the training phase (100 samples), with mean square error around 10^{-5} . Already at the diagnostic phase (network operation), the remaining 47 Nelore cows data that did not participate in the network training were submitted to the network, of these results, the network presented, on average, an error around 0.6% in relation to the desired output (normalized data), which resulted in an error of 1 sample of the 47 analyzed.

Keywords: Artificial intelligence; livestock; estimate; body mass index.

INTRODUÇÃO

O Índice de Massa Corporal (IMC) pode ser usado pelos agricultores para ajudar a determinar o tempo de avaliação do ganho de massa corporal do animal. No entanto, o cálculo deste índice não revela imediatamente se o animal está pronto para abate ou se necessita de cuidados especiais de engorda (GABRIEL FILHO et al., 2016). Com isso, visando utilizar uma modelagem matemática para que se possa classificar ou estimar automaticamente os dados de entrada com erro significativamente baixo, foi necessário ajustar os dados de saída (IMC) para torná-los mais precisos nos modelos, pois são esses dados que servirão de base para criação tanto das funções de pertinência da saída *fuzzy* como da camada de saída de uma rede neural artificial (RNA) com treinamento supervisionado. Neste sentido, em GABRIEL FILHO et al. (2011) foi desenvolvido um sistema baseado em regras *fuzzy*, que indica o índice de massa corporal de animais ruminantes. O método desenvolvido tem como saída um novo índice de massa corporal, denominado Índice de Massa Corporal *Fuzzy* (IMC *Fuzzy*) permitindo a classificação dos animais em qualquer rebanho através de um índice de massa corporal e estabelecer a identificação qualitativa e quantitativa para cada animal.

Em VENTURA et al., (2013) foi proposto o uso de RNAs na predição de valores genéticos em bovinos da raça Tabapuã. Os autores utilizaram como dados de entrada, idade da mãe ao parto, estação, região e o peso do animal e na camada de saída o valor genético. A RNA foi eficaz no reconhecimento de padrões e na predição do valor genético para uma massa de peso aos 205 dias de nascido, mas não foi recomendado o uso de RNA em avaliações genéticas quando se deseja inserir no futuro novos dados de animais que não estavam contidos na base de dados do treinamento.

Já em BITTENCOURT, (2009) foi proposto uma metodologia para aquisição de imagens digitais de carcaças bovinas durante o abate e a classificação automática do acabamento de gordura das carcaças. A metodologia foi baseada no uso de RNAs para segmentação das regiões de gordura e para classificar a carcaça em relação ao acabamento da gordura.

Vários outros trabalhos baseados em inteligência artificial e modelagem matemática foram desenvolvidos mostrando a importância de aplicações em áreas correlatas (BONINI et al., 2017, PUTTI et al., 2017, PUTTI et al., 2014, PEREIRA et al., 2008 e GARCIA et al., 2014).

Baseado nesse contexto, este trabalho tem por objetivo desenvolver uma ferramenta de classificação automática de bovinos via RNA e identificar os grupos de abate e os grupos que requerem alimentação mais intensiva, utilizando para

isso variáveis de entrada da rede como massa e altura do animal e como variável de saída (desejada), o IMC normalizado (IMC Nor) ou o IMC convencional e comparar os resultados com o proposto em GABRIEL FILHO et al. (2011).

MATERIAIS E MÉTODOS

O experimento foi realizado na cidade de Santa Rita do Pardo - Mato Grosso do Sul (MS), com um rebanho de

147 vacas Nelore variando entre 5 e 7 anos de idade. O IMC de cada animal foi calculado por meio da equação (1).

$$\text{IMC} = \frac{\text{massa}}{\text{altura}^2} \quad (1)$$

Em GABRIEL FILHO et al. (2011), o IMC *Fuzzy* foi calculado por meio de um

sistema *Fuzzy* representado no fluxograma da FIGURA 1 a seguir.

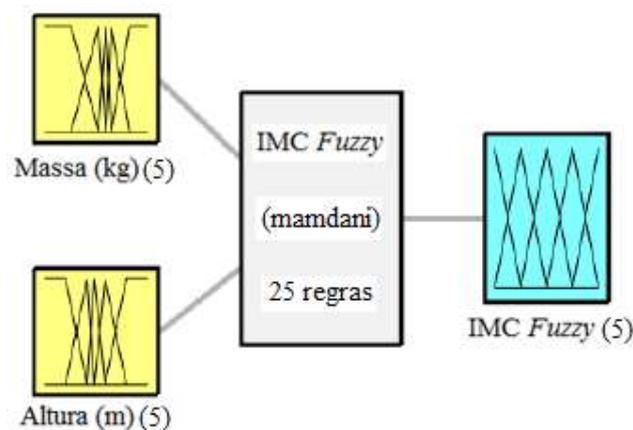


FIGURA 1. Fluxograma para cálculo do IMC *Fuzzy* proposto por GABRIEL FILHO et al. (2011).

O sistema *fuzzy* desenvolvido teve como entradas as variáveis massa e altura, e a saída um novo índice de massa corporal, denominado Índice de Massa Corporal *Fuzzy* (IMC *Fuzzy*), que pôde servir como um sistema de detecção do momento de abate de bovinos, comparando-os entre si através das variáveis linguísticas “Muito Baixa”, “Baixa”, “Média”, “Alta” e “Muito Alta”. Desta forma, o método possibilitou a avaliação do rebanho, comparando cada animal do rebanho com seus pares do grupo, fornecendo desta forma um método quantitativo de tomada de decisão para o pecuarista.

Da mesma forma que proposto em GABRIEL FILHO et al. (2011), e com o

intuito de criar uma ferramenta ainda mais simples na classificação de bovinos, optou-se neste trabalho em criar uma ferramenta baseada em RNA utilizando as mesmas entradas apresentadas no sistema *fuzzy* (massa e altura). Já para a saída desejada (rede supervisionada), foi utilizada o IMC Nor representado pela equação (2) ou o convencional por meio da equação (1) (não normalizado). A ideia de normalizar os dados de saída desejada é para concentrar os valores entre 0 e 1 facilitando no treinamento da rede e também na escolha da função de transferência (tangente hiperbólica) acarretando também em um erro bem menor no processo de treinamento se comparado aos dados não normalizados (convencional).

$$\text{IMC Nor} = \left(\frac{\text{massa}}{\text{altura}^2} \right) / \max(\text{IMC}) \quad (2)$$

em que o escalar $\max(\text{IMC})$ representa o maior valor do vetor IMC.

A FIGURA 2(a) representa as características de um neurônio artificial criado por MCCULLOCH e PITTS (1943) e a FIGURA 2(b) apresenta uma típica RNA com dois neurônios na camada de entrada (massa e altura), cinco neurônios na camada intermediária e um neurônio na camada de saída (IMC Nor ou

convencional) que foi utilizada neste trabalho. Trata-se de uma rede *Multilayer Perceptron* (MLP) (RUMELHART et al., 1986), aqui do tipo *feed forward* (sem realimentação) e com algoritmo de treinamento *backpropagation* (retropropagação do erro) com treinamento supervisionado (saída desejada).

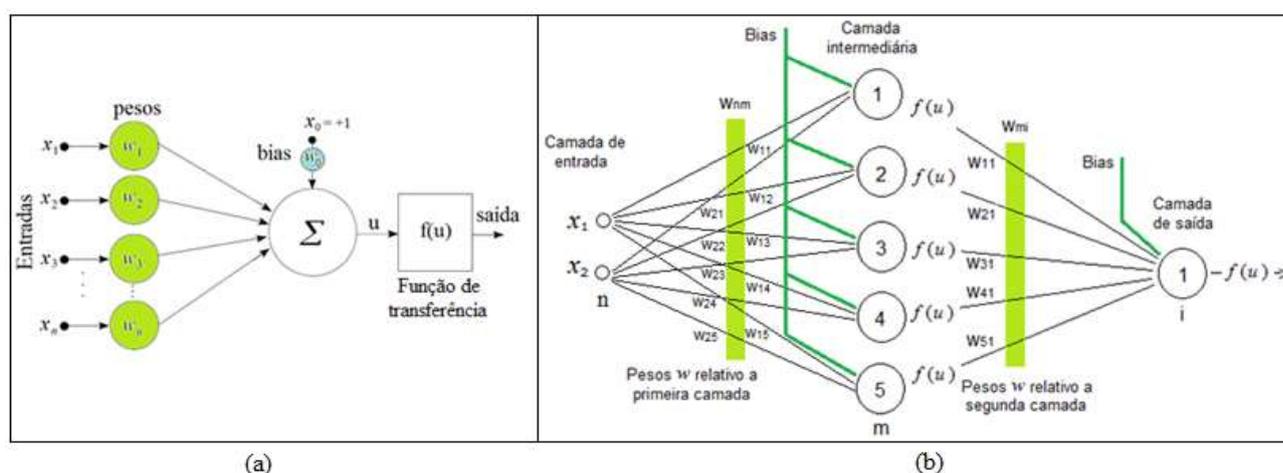


FIGURA 2. (a) Neurônio artificial, (b) RNA (*feed forward*) com 5 neurônios na camada intermediária.

Na FIGURA 2(a), o valor da saída u representa o somatório (Σ) dos produtos

das entradas (\mathbf{x}) pelos respectivos pesos (\mathbf{W}), conforme a equação (3).

$$u = \sum_{i=1}^n \mathbf{x}_i \mathbf{W}_i + \text{bias} \quad (3)$$

em que a soma do “bias” proporciona o aumento dos graus de liberdade, permitindo uma melhor adaptação, por parte da rede neural, ao conhecimento à ela fornecido. Por fim, $f(u)$ é a função de transferência para obter a saída da rede. A

função de ativação utilizada neste trabalho para a saída da camada intermediária é a função tangente hiperbólica (4) e para a camada de saída são as funções tangente hiperbólica (IMC Nor) e linear (5) (IMC), cujo os valores são maiores que 1.

$$f(u) = (1 - e^{-\lambda u}) / (1 + e^{-\lambda u}) \quad (4)$$

$$f(u) = u \quad (5)$$

em que λ é uma constante arbitrária e corresponde a inclinação da curva, neste trabalho $\lambda = 2$.

Uma rede neural típica é composta de n neurônios na camada de entrada, m neurônios na camada intermediária e i

neurônios na camada de saída, também conhecida como *Multilayer Perceptron* (MLP) do tipo *feed forward* (não recorrente, sem realimentação). Para este trabalho foram fixados $n=2$ (massa e altura), uma configuração para m , $m=5$ e por fim $i=1$ (IMC Nor ou IMC), conforme ilustrado na FIGURA 2(b). O valor mínimo e máximo para a saída IMC Nor foram 0.5159 e 1 e para o IMC foram 144.7984 e 280.6474 respectivamente. Estes valores são importantes para a escolha da função de transferência $f(u)$ na saída dos neurônios.

Quando RNAs de uma só camada são utilizadas, os padrões de treinamento apresentados à entrada são mapeados diretamente em um conjunto de padrões de saída da rede. Tal restrição implica que padrões de entrada similares resultem em padrões de saída similares, o que leva o sistema à incapacidade de aprender importantes mapeamentos. Como resultado, padrões de entrada com estruturas similares, fornecidos do mundo externo, que levem a saídas diferentes não são possíveis de serem mapeados por redes sem representações internas, isto é, sem camadas intermediárias (ICMC, 2017). Por isso optou-se em utilizar pelo menos uma camada intermediária (uma camada intermediária é suficiente para aproximar qualquer função contínua e produzir praticamente quaisquer mapeamentos). Nessas redes, cada camada tem uma função específica. A camada de saída recebe os estímulos da camada intermediária e constrói o padrão que será

a resposta. As camadas intermediárias funcionam como extratoras de características, seus pesos são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação, mais rica e complexa, do problema. Se existirem as conexões certas entre as unidades de entrada e um conjunto suficientemente grande de unidades intermediárias, pode-se sempre encontrar a representação que irá produzir o mapeamento correto da entrada para a saída através das unidades intermediária (ICMC, 2017)

A plataforma utilizada para a implementação computacional da RNA, bem como para a obtenção dos resultados, foi o Matlab® (MATHWORKS, 2017). O computador utilizado neste trabalho foi um Intel® Core i5 de 8 GB de memória.

Treinamento da RNA

O algoritmo de treinamento utilizado neste trabalho foi o *backpropagation* (retropropagação do erro) com treinamento supervisionado com algumas modificações (aproximação do mínimo da função erro pelo método de Newton) denominado de *Levenberg-Marquardt* (HAGAN, 1994), o qual considera a aprendizagem da rede a partir de dados de entrada e suas respectivas saídas desejadas (alvo) (BRAGA et al., 2007). Esse algoritmo é mais eficiente do que o algoritmo *backpropagation* padrão e suas variantes (LIU, 1996). A FIGURA 3 apresenta o fluxograma desse algoritmo (BITTENCOURT, 2009).

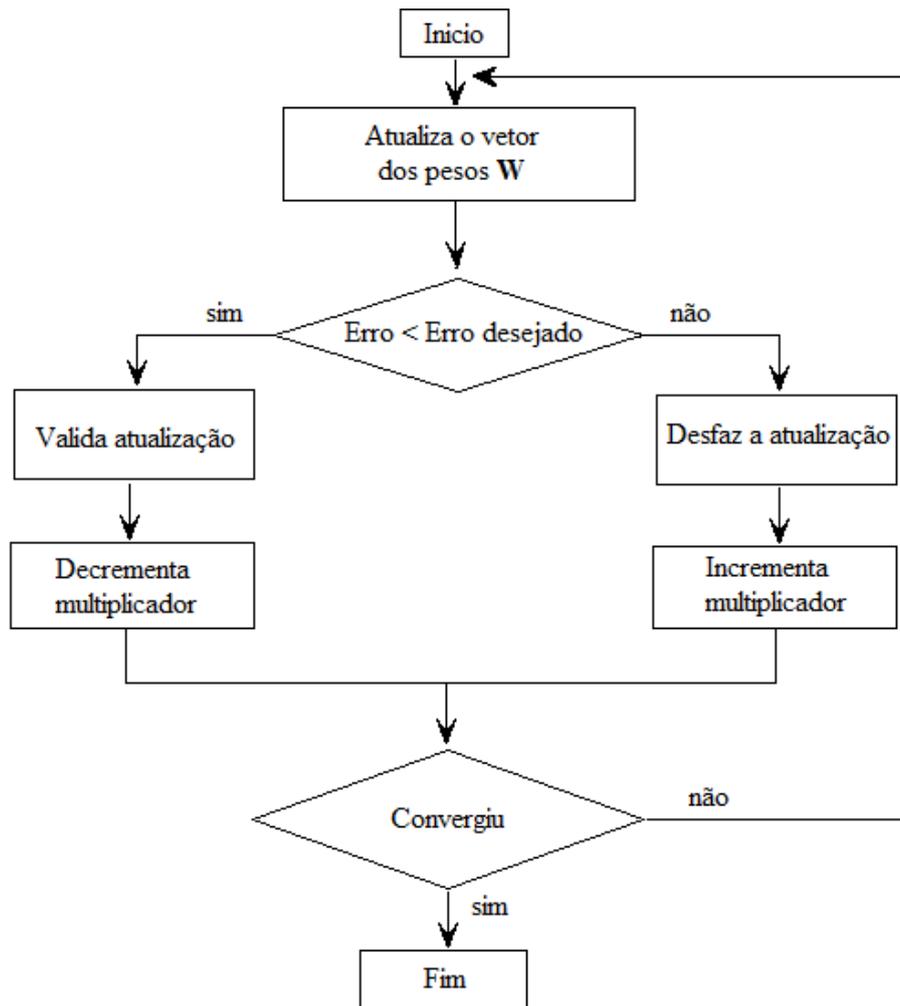


FIGURA 3. Fluxograma do algoritmo *backpropagation Levenberg-Marquardt*.

O treinamento consiste em conhecer um alvo a ser acertado para que a rede consiga adaptar seus pesos W_i de modo que, posteriormente, no processo de operação, conhecido também como diagnóstico da rede, possa se classificar ou estimar dados que não fizeram parte no processo de treinamento. Portanto, pode-se dizer que, a aprendizagem de uma RNA se dá pelo ajuste de seus pesos, W_i , durante o

treinamento e em função de dados de entrada cujas saídas são conhecidas.

Os critérios de parada relacionados ao treinamento da rede foram estabelecidos da seguinte forma: número máximo de iterações igual a 200; o valor a ser obtido para o erro quadrado médio (MSE, do inglês *Mean Square Error*) da equação (6) igual a 0.0001 (validação da rede) e o tempo máximo de treinamento igual a 20 segundos.

$$MSE = \frac{1}{t} \sum_{j=1}^t (Y_{j \text{ obtida}} - Y_{j \text{ desejada}})^2 \quad (6)$$

em que t é o número de amostras no processo de treinamento, $Y_{j \text{ obtida}}$ representa a saída obtida pela rede durante o

treinamento e $Y_{j \text{ desejada}}$ representa a saída desejada (alvo) a ser atingido pela rede e inserida antes do treinamento.

RESULTADOS

Para os resultados da RNA foram utilizadas 147 amostras (vacas Nelore), a qual, as 100 primeiras amostras foram utilizadas para o treinamento e o restante, 47 amostras foram utilizadas para o processo de diagnóstico da rede, ou seja, a fase de operação (simulação). Ambas as etapas (treinamento e diagnóstico) foram utilizadas as saídas desejadas IMC Nor e IMC.

A FIGURA 4(a) e (b) a seguir apresentam os resultados da fase de treinamento para as 100 primeiras amostras de vacas Nelore com 5 neurônios na camada intermediária. Pode-se notar, que mesmo utilizando diferentes saídas desejadas, os resultados são similares. Um aspecto importante e observado na FIGURA 4(b), é o erro. Embora, visualmente o erro aparenta estar muito baixo, não foi possível atingir ou até mesmo obter valores próximos ao estabelecido (0.0001) para o MSE no treinamento da rede. Isto ocorre devido ao

IMC ter valores entre 145 e 280, que são muito elevados para uma saída de rede. Com isso, o IMC Nor é uma alternativa atrativa para evitar esse problema.

A TABELA 1 refere-se ao desempenho da rede durante o treinamento para cada saída escolhida e para cada critério adotado. Pode-se observar que a rede que apresentou melhor desempenho no treinamento foi a que utilizou a saída desejada IMC Nor, convergiu com apenas 33 iterações em 0.12 segundo e o MSE de $9,01 \times 10^{-5}$ que ficou abaixo do estabelecido (10^{-4}) mostrando que os pesos W_i foram todos ajustados para a rede desenvolvida e pronta para a fase do diagnóstico (operação). A rede utilizando a saída IMC interrompeu o processo iterativo com 200 iterações, ou seja, no valor máximo estabelecido, apresentando um MSE de 0.617. Conforme comentado anteriormente, esse erro ocorreu devido aos valores muito elevados (entre 145 e 280) da saída.

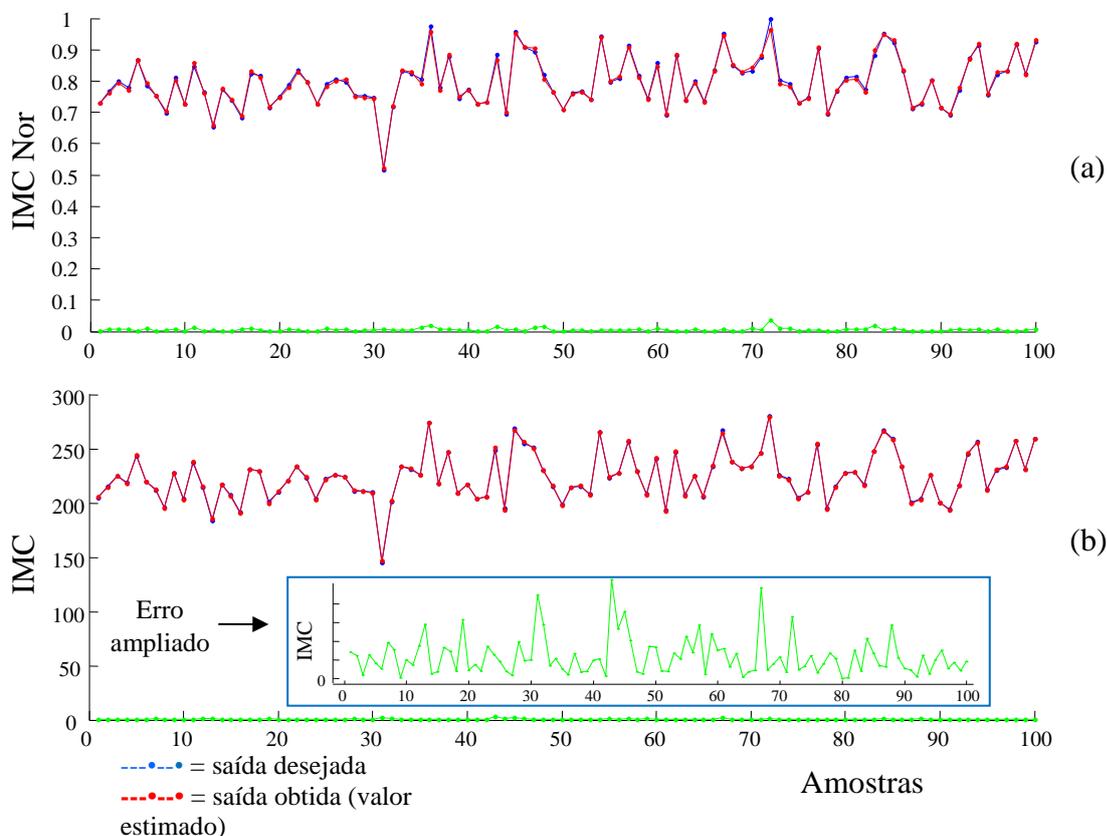


FIGURA 4. Fase de treinamento para as 100 primeiras amostras de vacas Nelore, (a) IMC Nor, (b) IMC.

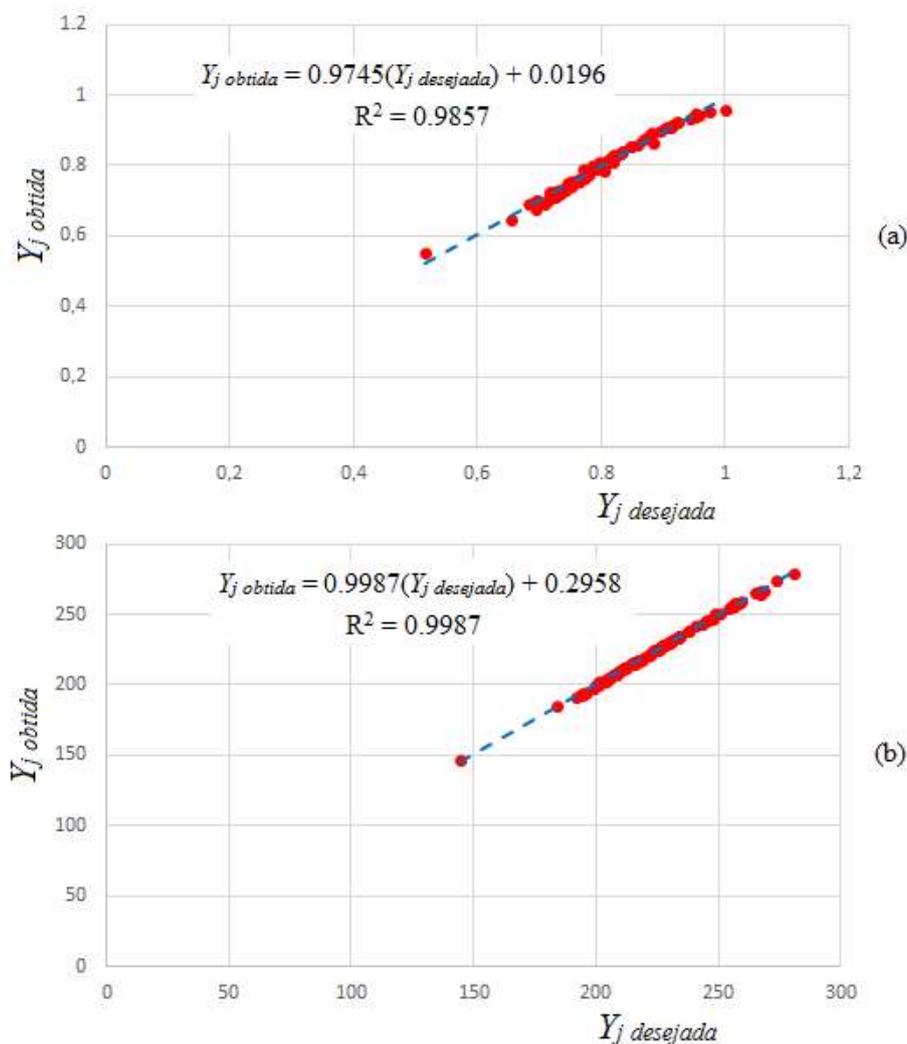
TABELA 1. Desempenho da RNA em relação as saídas IMC Nor e IMC.

Critérios de parada	Valor estabelecido max	IMC Nor	IMC
Iterações	200	33	200
MSE	10^{-4}	9.01×10^{-5}	0.617
Tempo (s)	20	0.12	1

■ Critério atingido

Na FIGURA 5 apresenta a reta de regressão e o R^2 , descrevendo a relação entre as variáveis Y_j obtida e Y_j desejada. Observa-se que o valor do R^2 são de 0.9857 e 0.9987 respectivamente, mostrando que em média 99% da variável

Y_j obtida consegue ser explicada pelos métodos presentes no modelo, ou seja, mais explicativo é o modelo, melhor ele se ajusta à amostra (PAGANO e GAUVREAU, 2012).

**FIGURA 5.** Análise de regressão, (a) IMC Nor, (b) IMC

Diagnóstico (Operação da rede)

Uma vez todos os pesos W_i obtidos pelo processo de treinamento, passamos agora para a fase do diagnóstico da rede, ou seja, simular as 47 amostras restantes de vacas Nelore que não fizeram parte do

treinamento. A FIGURA 6 apresenta esses resultados. A FIGURA 6(a) mostra o processo de operação da rede comparando com a saída desejada IMC Nor, o erro foi menor, 0.0067, ou seja, 0.6% na comparação. Esse erro baixo era esperado,

pois no processo de treinamento o MSE foi de 9.01×10^{-5} . E por fim, na FIGURA 6(b), utilizando a saída IMC, o erro foi de 0.6234, considerado alto, cerca de 62%,

isso pode ser comprovado ao observar o erro ampliado da FIGURA 6(b) e também no processo de treinamento da rede com MSE de 0.617.

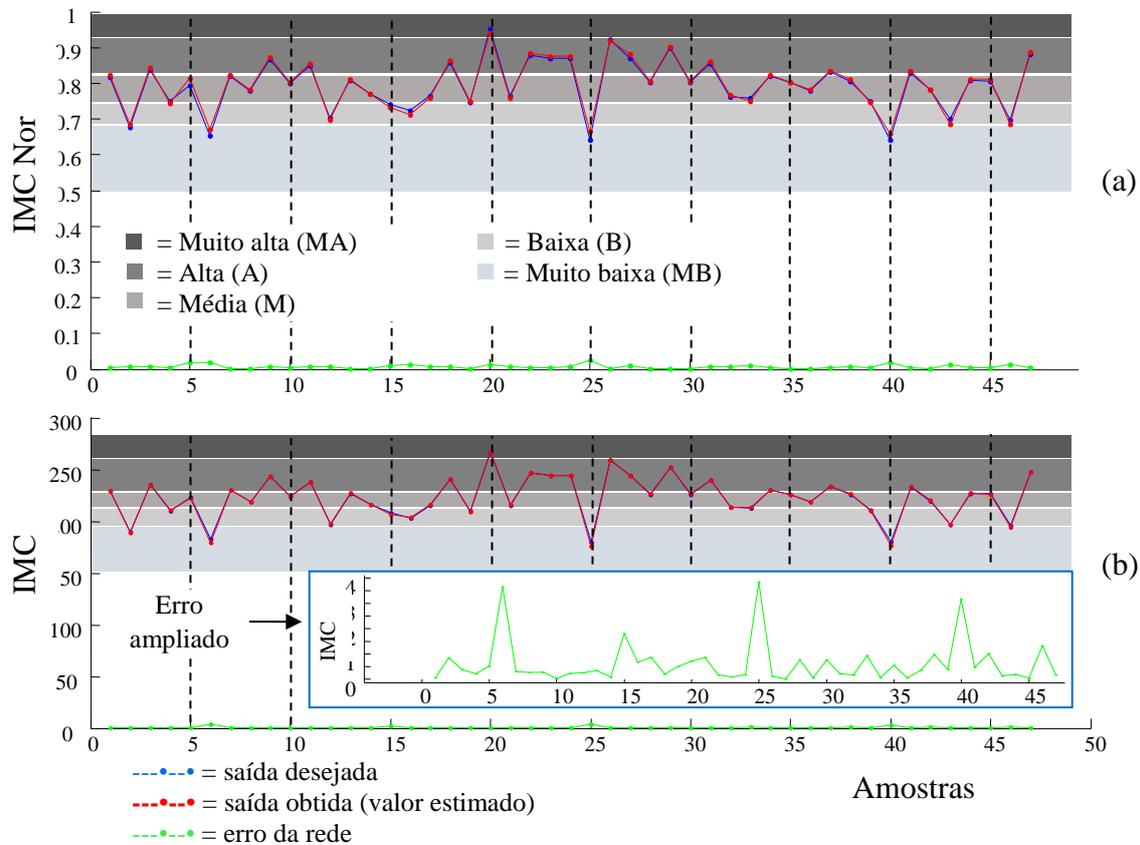


FIGURA 6. Diagnóstico da rede para 47 amostras de vacas Nelore, (a) IMC Nor, (b) IMC.

Em GABRIEL FILHO et al. (2011) foi estabelecido uma faixa de valores para o IMC *Fuzzy*, estabelecido como muito alto (MA), alto (A), médio (M), baixo (B) e muito baixo (MB) conforme visto na FIGURA 7. A partir desses valores também foi possível obter uma faixa correspondente ao IMC Nor, podendo assim analisar cada amostra de vaca e estabelecer um procedimento (abate ou engorda) via RNA e compará-los com resultados proposto por GABRIEL FILHO et al. (2011). Um exemplo pode ser dado para as 5 primeiras amostras de vacas

Nelores da FIGURA 7. Analisando estas amostras, podemos inferir que as primeira e terceira amostras estão prontas para o abate, faixa com valor alto (A). A quinta amostra está com valor em médio (M), quase pronta para o abate e a segunda e quarta amostras, requerem alimentação mais intensiva, com valores em muito baixo (MB) e baixo (B) respectivamente. O erro médio entre as duas metodologias foi de 0.0528 mostrando que a RNA também pode ser uma ferramenta bem atrativa para esse tipo de aplicação.

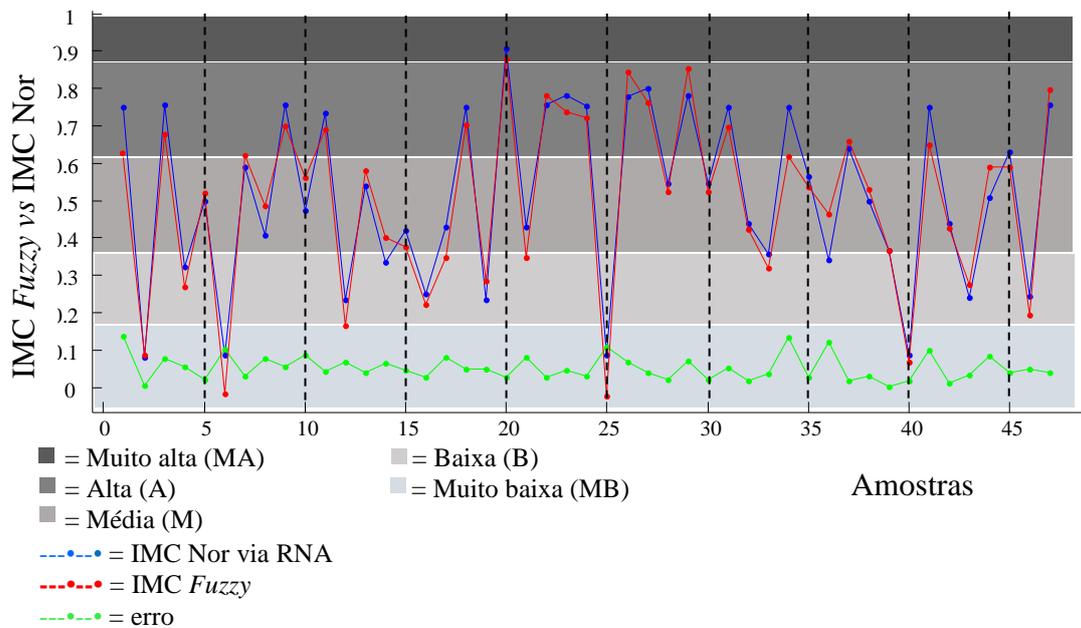


FIGURA 7. Comparação entre as saídas IMC Nor via RNA proposta neste trabalho e IMC *fuzzy* proposta por GABRIEL FILHO et al. (2011).

CONCLUSÕES

Foi desenvolvido uma ferramenta de classificação automática de bovinos por intermédio de uma Rede Neural Artificial (RNA) e identificar os grupos de abate e os que requerem alimentação mais intensiva, utilizando como variáveis de entrada da rede massa e altura e como variável de saída, o índice de massa corporal normalizado (IMC Nor) e o IMC convencional. Dos resultados podemos concluir que a RNA pôde classificar as

amostras que não fizeram parte do treinamento e com um melhor resultado para a rede cuja a saída foi o IMC Nor, devido ao MSE menor (9.01×10^{-5}) no treinamento acarretando em valores muito próximos dos desejados.

Os resultados também foram comparados com o proposto na literatura mostrando que as RNA obteve resultados com semelhança em torno de 99%.

REFERÊNCIAS

BITTENCOURT, C. D. R. Classificação automática do acabamento de gordura em imagens digitais de carcaças bovinas. Dissertação apresentada à Universidade de Brasília. 78 p. 2009.

BONINI NETO, A.; BONINI, C. S. B.; BISI, B. S.; DOS REIS, A. R.; COLETTA, L. F. S. Artificial neural network for classification and analysis of degraded soils. **Revista IEEE América Latina**, v. 15, n. 3, p. 503-509, 2017.

BRAGA, A. DE P.; CARVALHO, A. P. DE L. F. DE; LUDERMIR, T. B. Redes

neurais artificiais: teoria e aplicações. 2. ed. Rio de Janeiro: LTC Editora, 2007.

GABRIEL FILHO, L. R. A.; CREMASCO, C. P.; PUTTI, F. F.; CHACUR, M. G. M. Application of fuzzy logic for the evaluation of livestock slaughtering. **Engenharia Agrícola**, Jaboticabal, v. 31, p. 813-825, 2011.

GABRIEL FILHO, L. R. A.; PUTTI, F. F.; CREMASCO, C. P.; DEYVER BORDIN, CHACUR, M. G. M.; GABRIEL, L. R. A. Software to assess beef cattle body mass through the fuzzy body mass index.

Engenharia Agrícola, Jaboticabal, v. 36, n. 1, p. 179-193, 2016.

GARCIA, A. P.; CAPPELLI, N. L.; UMEZU, C. K. Electrically driven fertilizer applicator controlled by fuzzy logic. **Engenharia Agrícola**, Jaboticabal, v.34, n.3, p. 510-522, 2014.

HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the marquardt algorithm. **IEEE Transactions on Neural Networks**, v.5, n.6, p. 989-993, 1994.

ICMC. Disponível no site do ICMC da Universidade de São Paulo - USP em: <<http://conteudo.icmc.usp.br/pessoas/andre/research/neural/index.htm#links>> Acesso em 9 de agosto de 2017.

LIU, Y. Calibrating an industrial microwave six-port instrument using artificial neural network technique. **IEEE Transactions on Instrumentation and Measurement**, v.45, n.2, p. 651-656, 1996.

MATHWORKS. MATLAB (MATrix LABoratory) Disponível em: <<http://www.mathworks.com>>. Acesso em 21 de maio de 2017.

MCCULLOCH, W. S. e PITTS, W. A. Logical Calculus of the Ideas Immanent in Nervous Activity, **Bulletin of Mathematical Biophysics**, n.9, pp. 127-147, 1943.

PAGANO, M.; GAUVREAU, K. Princípios de Bioestatística. São Paulo: Cengage Learning, 506p. 2012.

PEREIRA, D. F.; BIGHI, C. A.; GABRIEL FILHO, L. R. A.; CREMASCO, C. P. C. System fuzzy for estimate of welfare of broiler breeders. **Engenharia Agrícola**, Jaboticabal, v.28, p. 624-634, 2008.

PUTTI, F. F.; GABRIEL FILHO, L. R. A.; SILVA, A. O.; LUDWIG, R.; GABRIEL, C. P. C. Fuzzy logic to evaluate vitality of *Catasetum fimbriatum* species (Orchidaceae). **Irriga**, Botucatu, v. 19, n.3, p. 405-413, 2014.

PUTTI, F. F.; GABRIEL FILHO, L. R. A.; CREMASCO, C. P. C.; BONINI NETO, A.; BONINI, C. S. B.; REIS, A. R. A Fuzzy mathematical model to estimate the effects of global warming on the vitality of *Laelia purpurata* orchids. **Mathematical Biosciences**, v. 288, p. 124-129, jun. 2017.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, v. 323, p. 533, 9 out. 1986.

VENTURA, R. V.; SILVA, M. A.; MEDEIROS, T. H.; DIONELLO, N. L.; MADALENA, F. E.; FRIDRICH, A. B.; VALENTE, B. D.; SANTOS, G. G.; FREITAS, L. S.; WENCESLAU, R. R.; FELIPE, V. P. S.; CORRÊA, G. S. S. Uso de redes neurais artificiais na predição de valores genéticos para peso aos 205 dias em bovinos da raça Tabapuã. **Arq. Bras. Med. Vet. Zootec.**, v.64, n.2, p.411-418, 2012.