

CONTROLE DE RESPOSTAS PRODUTIVAS E FISIOLÓGICAS EM FRANGOS DE CORTE UTILIZANDO REDES NEURAS ARTIFICIAIS

MARCELO BAHUTI¹, LUCAS HENRIQUE PEDROZO ABREU², TADAYUKI YANAGI JUNIOR³, PATRÍCIA FERREIRA PONCIANO FERRAZ⁴, YAMID FABIÁN HERNÁNDEZ JULIO⁵

¹ Graduando em Eng. Agrícola, Depto. de Engenharia, UFLA/Lavras-MG, (35) 3829.1481, marcelo_bahuti@hotmail.com

² Eng. Agrícola, Prof. Dr., Depto.de Engenharia, UFLA/Lavras-MG, (35) 3829.1481, lucas.abreu@deg.ufla.br

³ Eng. Agrícola, Prof. Dr., Depto.de Engenharia, UFLA/Lavras-MG, (35) 3829.1481, yanagi@deg.ufla.br

⁴ Zootecnista, Prof. Dr., Depto.de Engenharia, UFLA/Lavras-MG, (35) 3829.1481, patyponciano@yahoo.com.br

⁵ Doutorando em Eng. De Sistemas, Universidad del Norte, Colômbia, (35) 3829.1481, yafaheju@hotmail.com

Apresentado no
XLVI Congresso Brasileiro de Engenharia Agrícola - CONBEA 2017
30 de julho a 03 de agosto de 2017 - Maceió - AL, Brasil

RESUMO: As condições do ambiente de criação têm efeito significativo sobre o conforto térmico das aves de corte, e pode ser averiguado através das respostas fisiológicas e produtivas desses animais. A fim de prever respostas como, conversão alimentar (CA), consumo de água ($C_{\text{água}}$) e temperatura cloacal (t_{clo}) de frangos de corte, sobre diferentes intensidades ($^{\circ}\text{C}$) e durações (dias) de estresse térmico, durante a segunda semana de vida, foi desenvolvida uma rede neural artificial (RNA). Para realização do experimento foram utilizados 240 frangos da linhagem *Cobb 500*[®] confinados em túneis de vento climatizados. As variáveis de entrada foram, temperatura de bulbo seco do ar (24, 27, 30 e 33 $^{\circ}\text{C}$), duração do estresse (1, 2, 3, 4 dias) e dias após estresse (0, 1, 2, 3, 4 e 5 dias). A arquitetura para predição foi a rede de multicamadas (*Multi-Layer perceptron*, MLP) por apresentar menor erro quadrado médio. Quando comparados os valores experimentais com os dados de saída do modelo RNA, apresentou-se coeficientes de determinação (R^2) de 0,79, 0,87 e 0,97, para a t_{clo} , CA e $C_{\text{água}}$ respectivamente. Podendo assim, ser utilizado como suporte à tomada de decisão nos sistemas de criação de frangos de corte.

PALAVRAS-CHAVE: frangos de corte, respostas produtivas, redes neurais

CONTROL OF PRODUCTIVE AND PHYSIOLOGICAL RESPONSES IN BROILERS USING ARTIFICIAL NEURAL NETWORKS

ABSTRACT: The conditions of the creation environment have a significant effect on the thermal comfort of the broilers, and can be ascertained through the physiological and productive responses of these animals. In order to predict responses such as feed conversion (FC), water consumption (WC) and cloacal temperature (t_{clo}) of broilers, on different intensities ($^{\circ}\text{C}$) and durations (days) of thermal stress during the second week of life, an artificial neural network (ANN) was developed. To perform the experiment, were used 240 broilers of the *Cobb 500*[®] lineage confined in air-conditioned wind tunnels. The input variables were dry bulb air temperature (24, 27, 30 and 33 $^{\circ}\text{C}$), duration of stress (1, 2, 3, 4

days) and days after stress (0, 1, 2, 3, 4 and 5 days). The architecture for prediction was the multilayer network (Multi-Layer perceptron, MLP) because it presented smaller mean square error. When comparing the experimental values with the ANN model output data, were presented coefficients of determination (R^2) of 0.79, 0.87 and 0.97 for t_{clo} , FC and WC, respectively. Therefore, it can be used as support for decision making in broilers creation systems.

KEYWORDS: broilers, productive responses, neural networks

INTRODUÇÃO

No Brasil, devido as amplitudes climáticas, é de extrema dificuldade manter um ambiente térmico que favoreça o crescimento de aves de corte nas instalações de criação (FERRAZ et al., 2014). Em vista disso, tem-se o interesse em averiguar a influência do manejo e do microclima sobre os níveis de estresse dos animais e qual a magnitude da interferência nos parâmetros de produção (PADNDORFI et al., 2012).

Os fatores que afetam as funções vitais dos frangos são, temperatura e umidade do ar (COSTA et al., 2012). A utilização controlada dessas variáveis é imprescindível para uma ótima produtividade e sucesso do empreendimento avícola (MARCHINI 2003). Entre as medidas relevantes para verificação da aclimação das aves no ambiente de criação estão as respostas produtivas e fisiológicas (SOUZA et al., 2010).

Quando expostos a condições de estresse calorífico, os frangos de corte apresentam desequilíbrio alimentar, que por sua vez, acarretam alterações negativas no ganho de peso e na conversão alimentar (MARCHINI 2012; CORDEIRO et al., 2014). Já a alteração do comportamento fisiológico em decorrência do estresse térmico pode ser averiguada por meio da temperatura cloacal (DIONELLO et al., 2002).

Como ambas respostas estão sujeitas a alterações diversificadas devido a duração e intensidade do agente estressor (MARCHINI 2012), a previsão de respostas é uma alternativa para auxílio a tomada de decisão, e pode ser realizada através de redes neurais artificiais (RNAs) em busca de padrões e técnicas para o controle térmico na área de produção (FERRAZ et al., 2014).

As RNAs são modelos computacionais baseados na estrutura do cérebro humano, na tentativa de copiar o funcionamento da inteligência de um neurônio biológico, criando um software de inteligência artificial, podendo dessa forma, ser implantada nas granjas para auxílio técnico e diminuição de custos e perdas (SPOHR 2011).

Em vista disso, a pesquisa tem por objetivo desenvolver uma RNA para predição de respostas produtivas e fisiológicas em frangos de corte, submetidos a diferentes intensidades e durações de estresse térmico, durante a segunda semana de vida.

MATERIAL E MÉTODOS

O experimento foi conduzido em laboratório climatizado, com pé direito de 3,5 metros e área total equivalente a 31,92 m², equipado com dois sistemas de ar condicionado com potência de 18.000 BTUs cada, e com quatro tuneis de ar, no qual, são equipados por resistências e nebulizadores. Em cada túnel de vento foi posicionada uma gaiola com 0,24 m², dividida em três repartições, delimitando assim as repetições em cada gaiola.

Duzentos e quarenta frangos de corte *Cobb 500*[®] foram utilizados, sendo sessenta em cada etapa e quinze por túnel durante a primeira semana do experimento. Assim, a cada

semana uma ave era retirada de todas as repartições das gaiolas, iniciando a segunda e terceira semana com 4 e 3 aves, respectivamente.

Cada etapa durou 21 dias e foram divididas pelas temperaturas de bulbo seco do ar (tbs) utilizadas no tratamento durante a segunda semana de vida das aves (24, 27, 30 e 33 ° C), proporcionando estresse por baixas e altas temperaturas. Na mesma etapa, cada um dos 4 túneis de ar foram submetidos a uma duração de estresse (1, 2, 3 ou 4 dias) nos dias 8, 9, 10 e 11 do período experimental, posteriormente, no decorrer da segunda semana, as temperaturas retornaram a zona de termoneutralidade. Os demais dias de criação que compõem os 21 dias do período experimental foram mantidos em temperatura de conforto térmico conforme literatura (CONY & ZOCHE, 2004) (Tabela 1).

A alimentação das aves foi por meio de ração balanceada, formulada à base de milho e farelo de soja, seguindo as recomendações nutricionais de Rostagno et al. (2011). Tanto ração quanto água estavam disponíveis *ad libitum*.

A umidade relativa do ar foi mantida em 60% e a velocidade do ar em 0,2 ms⁻¹, conforme recomendado para correta aclimação das aves de corte por Medeiros et al. (2005). Por sua vez, a luminosidade foi ajustada com intensidades de 25, 10 e 5 lux para a primeira, segunda e terceira semana de vida, respectivamente (COBB, 2008).

TABELA 1. Temperatura de bulbo seco do ar (24, 27, 30 ou 33 ° C) e dias da condição de estresse térmico (em negrito), aplicados a frangos de corte. **Air dry bulb temperature (24, 27, 30 or 33 ° C) and days of the thermal stress condition (in bold), applied to broilers.**

		Temperatura de bulbo seco do ar (tbs, ° C)								
Etapa	Túnel	Dias de Vida								
		1 a 7	8	9	10	11	12	13	14	15 a 21
N	A		tbs	30	30	30	30	30	30	
	B	33	tbs	tbs	30	30	30	30	30	27
	C		tbs	tbs	tbs	30	30	30		
	D		tbs	tbs	tbs	tbs	30	30	30	

N é o número da etapa (1, 2, 3 ou 4) composta por uma única tbs (24, 27, 30 ou 33 ° C).

Após a coleta dos dados experimentais, iniciou-se a construção da RNA para prever as variáveis, conversão alimentar (CA, em g g⁻¹), consumo de água (C_{água}, em ml/dia) e temperatura cloacal (t_{clo}, em ° C), a partir dos dados de entrada de tbs (24, 27, 30 ou 33 ° C), duração do estresse (DE; 1, 2, 3 ou 4 dias) e dias após o estresse (DA; 0, 1, 2, 3, 4 ou 5 dias).

Para desenvolver os modelos baseados em RNA foi utilizado o *software* Matlab[®] (R2011b), com o uso da ferramenta de ajuste neural (MATHWORKS, 2013). As configurações do modelo incluem o número de camadas ocultas, as funções de transferência em cada camada escondida, o número de neurônios na camada escondida, a taxa de aprendizagem, a taxa de momento e os pesos dos neurônios.

Foram utilizados 360 pares de dados, sendo que, 252 foram usados para treinamento, 54 para validação e outros 54 para a realização dos testes. No treinamento foram usados diferentes números de neurônios ocultos (de 1 a 20, contando de 1 em 1, de 25 a 200, contando de 5 em 5 e de 210 a 300 contando de 10 em 10) para o teste. Desenvolveram-se 61 modelos baseados em RNA com 10 repetições cada, para prever a t_{clo}, CA e C_{água}, e selecionou-se a arquitetura que apresentou o maior coeficiente de correlação (R²) e o menor erro quadrado médio (EQM).

Duas camadas feedforward e treinamento supervisionado foram empregados com o algoritmo de treinamento Levenberg-Marquardt backpropagation, que é considerado o

método mais rápido para a formação das redes (BARBOSA et al., 2005). O EQM foi utilizado para a função de desempenho do modelo, no qual, para a saída do neurônio selecionou-se a função de ativação tangente sigmoideal (FERRAZ et al., 2014).

Os parâmetros de rede iniciais foram configurados como segue: camada oculta (1, valor padrão), o número de épocas (1000), a tolerância de erro (<0,099), taxa de aprendizagem (0,7), e taxa de momento (1×10^{-3}) (HERNÁNDEZ-JULIO et al., 2014). Por fim, para a análise de significância dos coeficientes da RNA utilizou-se os testes F e t ($p < 0,05$).

RESULTADOS E DISCUSSÃO

A arquitetura testada que apresentou o melhor desempenho para predição da t_{clo} , CA, e $C_{\text{água}}$ foi a rede de multicamadas (*Multi-Layer perceptron*, MLP), sendo que, os erros foram de 59,16; 102,27 e 67,23, no processo de treinamento, validação e teste, respectivamente.

O aprendizado da rede é importante para aumentar a acurácia no reconhecimento de padrões (PANDORFI et al., 2011), assim, o sistema efetuou alterações nos pesos sinápticos até atingir o menor erro. O modelo com o menor erro foi obtido com a camada oculta constituída por 50 neurônios com o menor EQM na décima época.

A simulação do modelo foi realizada em função da combinação das variáveis de entrada t_{bs} , DE e DA, para prever a t_{clo} , CA e $C_{\text{água}}$, ou seja, a camada de saída foi composta por três neurônios. Os valores simulados foram comparados com os dados experimentais obtidos nos túneis de vento climatizados, sendo determinadas as médias, as medianas, os valores mínimos e máximos para o desvio médio, desvio padrão e erro percentual (Tabela 2).

TABELA 2. Indicadores estatísticos para comparação entre os valores obtidos experimentalmente e simulados pelo modelo para a temperatura cloacal, conversão alimentar e consumo de água de frangos de corte. **Statistical indicators for comparison between experimental and simulated values by the model for cloacal temperature, feed conversion and water consumption of broilers.**

Índices	Temperatura cloacal				Conversão alimentar				Consumo de água			
	Mín.	Med.	Medi.	Máx.	Mín.	Med.	Medi.	Máx.	Mín.	Med.	Medi.	Máx.
Desvio médio	0,00	0,13	0,07	0,81	0,00	0,07	0,05	0,34	0,00	2,24	1,20	11,52
Desvio Padrão	0,00	0,09	0,05	0,57	0,00	0,05	0,04	0,24	0,00	1,59	0,85	8,14
Erro (%)	0,00	0,30	0,18	1,95	0,10	4,85	3,43	21,7	0,00	2,05	1,10	9,98

Mín.= Mínimo; Med.= Média; Medi.= Mediana; Máx.= Máximo.

Ferreira et al. (2010) desenvolveram um modelo neuro-*fuzzy* para prever a t_{clo} de frangos de corte em função da umidade relativa, t_{bs} e velocidade do ar, sendo que, o resultado do desvio médio entre os valores preditos e mensurados experimentalmente foi de 0,11°C. Por sua vez, nesse trabalho, o desvio médio para a predição da t_{clo} foi de 0,13 °C, demonstrando boa eficiência em ambas as redes.

Os coeficientes de regressão, para todas variáveis de saída, foram significativos pelo teste t, ($p < 0,05$). Todas as regressões foram significativas pelo teste F ($p < 0,05$) sendo o coeficiente de determinação (R^2) para t_{clo} , CA e $C_{\text{água}}$ equivalentes a 0,870; 0,792 e 0,976, respectivamente (Figura 1).

A eficiência do modelo apresentado neste estudo corrobora com os estudos realizados por Ferraz et al. (2014), que utilizou a RNA para prever a massa corporal de pintinhos sobre diferentes condições de estresse calorífico, no qual obteve valor de R^2 equivalente a 0,9993, certificando a boa acurácia da inteligência artificial em prever respostas de frangos de corte.

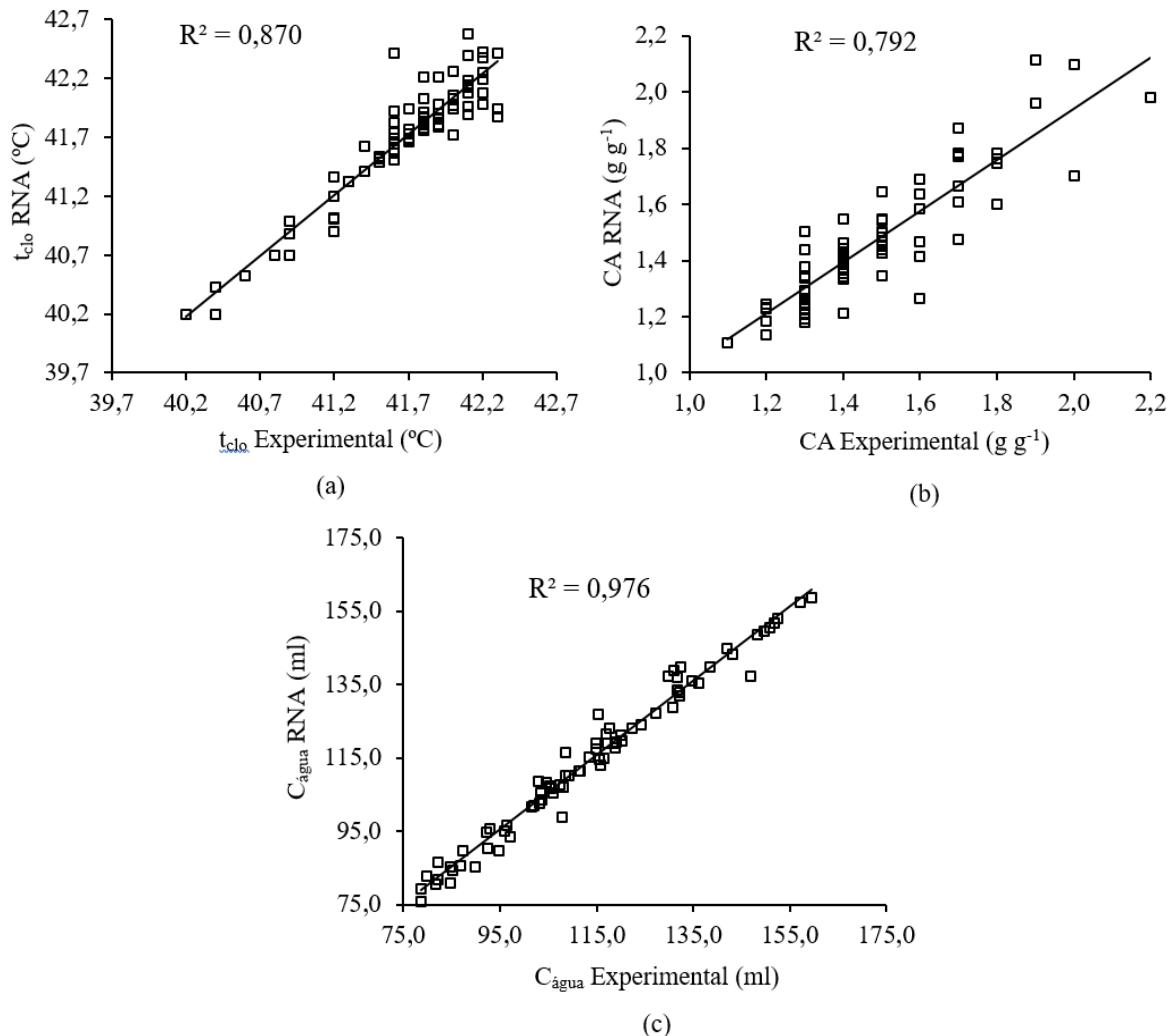


FIGURA 1. Regressões lineares para (a) temperatura cloacal (t_{clo}), (b) consumo de água ($C_{água}$) e (c) conversão alimentar (CA) obtidas experimentalmente e simuladas pelo modelo RNA.

CONCLUSÕES

A aplicação das redes neurais artificiais na avaliação do bem-estar em frangos de corte submetidos a diferentes intensidades e durações de estresse térmico, durante a segunda semana de vida, fornece informações para o correto manejo das aves. A partir da análise das variáveis temperatura cloacal, conversão alimentar e consumo de água, é possível encontrar o melhor controle do ambiente térmico, podendo dessa forma ser embarcado em sistemas para controle e auxílio à tomada de decisão.

AGRADECIMENTOS

Os autores expressam os seus agradecimentos a CAPES ao CNPq e FAPEMIG pelo suporte financeiro a esta pesquisa.

REFERÊNCIAS

- BARBOSA, A.H.; FREITAS M.S.R.; NEVES, F.A. Confiabilidade estrutural utilizando o método de Monte Carlo e redes neurais. **REM: Revista Escola de Minas**, v.58, p.247-255, 2005.
- COBB. Broiler Management Guide. Arkansas: Cobb-Vantress USA, 65p. 2008.
- CORDEIRO, M.; FREITAS, H. D.; AQUINO, E.; SOUSA, E. Avaliação do estresse térmico em frangos caipiras criados em condições climáticas do Estado do Acre. **Enciclopédia Biosfera**, v. 10, p. 358-365, 2014.
- CONY, A.V.; ZOCHE, A.T. **Manejo de frangos de corte**. In: MENDES, A.; NÄÄS, I. de A.; MACARI, M. (Ed.). Produção de frangos de corte. Campinas: Facta, 2004. p.118-136.
- COSTA, J.H.S.; SARAIVA, E.P.; SANTOS, L.D. Efeito do ambiente sobre indicadores fisiológicos na produção de frangos de corte. **Revista Verde de Agroecologia e Desenvolvimento Sustentável**, Mossoró, v.7, n.4, p.54–58, jan./dez. 2012.
- DIONELLO, N. J. L.; MACARI, M.; FERRO, J. A.; RUTZ, F.; FERRO, M. I. T.; FURLAN, L. R. Respostas fisiológicas associadas à termo tolerância em pintos de corte de duas linhagens por exposição a altas temperaturas. **Revista Brasileira de Zootecnia**, v. 31, n. 3, p. 79-85, 2002.
- FERRAZ, P. F. P.; YANAGI JUNIOR, T.; JULIO, Y. F. H.; CASTRO, J. O., GATES, R. S.; REIS, G. M.; CAMPOS, A. T. Predicting chick body mass by artificial intelligence-based models. **Pesquisa Agropecuária Brasileira**, v. 49, n. 7, p. 559-568, 2014.
- FERREIRA, L.; JUNIOR, T. Y.; LOPES, A. Z.; LACERDA, W. S. Desenvolvimento de uma rede neuro-fuzzy para predição da temperatura retal de frangos de corte. **Revista de Informática Teórica e Aplicada**, v. 17, n. 2, p. 221-233, 2010.
- HERNÁNDEZ-JULIO, Y. F.; YANAGI JR, T.; DE FÁTIMA ÁVILA PIRES, M.; AURÉLIO LOPES, M.; RIBEIRO DE LIMA, R. Models for Prediction of Physiological Responses of Holstein Dairy Cows. **Applied Artificial Intelligence**, v. 28, n. 8, p. 766-792, 2014.
- MARCHINI, C. F. P. **Desempenho, alterações ósseas e intestinais de frangos de corte submetidos ao estresse cíclico por calor**. Tese de Doutorado. Tese (Doutorado) Escola de Veterinária e Zootecnia da Universidade Federal de Goiás, 2012.
- MARCHINI, C. F. P. **Influência do estresse calórico no desempenho produtivo e parâmetros fisiológicos de frango de corte**. Monografia (Pós-Graduação) Universidade Federal de Uberlândia, 2003.
- MATHWORKS I. 2013. **Levenberg–Marquardt backpropagation**. The MathWorks, Inc., 2013.
- MEDEIROS, C. M.; BAÊTA, F. D. C.; OLIVEIRA, R. D.; TINÔCO, I. D. F. F.; ALBINO, L. F. T.; CECON, P. R. Efeitos da temperatura, umidade relativa e velocidade do ar em frangos de corte. **Engenharia na Agricultura**, Viçosa, MG, v. 13, n. 4, p. 277-286, 2005.
- PANDORFI, H.; ALMEIDA, G. L. P.; GUISELINI, C. Zootecnia de precisão: princípios básicos e atualidades na suinocultura. **Revista Brasileira de Saúde e Produção Animal**, v. 13, n. 2, p. 558-568, 2012.
- PANDORFI, H.; SILVA, I.J.O.; SARNIGHAUSEN, V.C.R.; VIEIRA, F.M.C.; NASCIMENTO, S.T.; GUISELINI, C. Uso de redes neurais artificiais para predição de índices zootécnicos nas fases de gestão e maternidade na suinocultura. **Revista Brasileira de Zootecnia**, v.40, n.3, p.676-681, 2011.

ROSTAGNO, H. S.; ALBINO, L. F. T.; DONZELE, J. L.; GOMES, P. C.; OLIVEIRA, R. F.; LOPES, D. C.; FERREIRA, A. S.; BARRETO, S. L. T.; EUCLIDES, R. F. Tabelas brasileiras para aves e suínos: composição de alimentos e exigências nutricionais. 3.ed. Viçosa, MG: Universidade Federal de Viçosa, 2011.

SOUZA, V. L. F.; BURANELO, G. S.; GASPARINO, E.; CARDOZO, R. M.; BARBOSA, M. J. B. Efeito da automatização nas diferentes estações do ano sobre os parâmetros de desempenho, rendimento e qualidade da carne de frangos de corte. **Acta Scientiarum. Animal Sciences**, v. 32, n. 2, p. 175-181, 2010.

SPOHR, A. **Gerenciamento através de redes neurais artificiais das atividades de produção de reprodutoras pesadas e do frango de corte, de um incubatório e de um abatedouro avícola**. Dissertação (Mestrado) Universidade Federal do Rio Grande do Sul, 2011.