

## REDES NEURAIS NA PREDIÇÃO DA VAZÃO IDEAL DE EXAUSTORES EM AVIÁRIOS DE FRANGO DE CORTE COM DIFERENTES TIPOLOGIAS

THAYLA MORANDI RIDOLFI DE CARVALHO CURI<sup>1</sup>, DANIELLA JORGE DE MOURA<sup>2</sup>, JULIANA MARIA MASSARI<sup>3</sup>, RIMENA DO AMARAL VERCELLINO<sup>4</sup>, LUANA ARAÚJO SABINO<sup>5</sup>

<sup>1</sup> Doutora, Faculdade de Engenharia Agrícola – UNICAMP, Fone: (19) 3521-1026, thaylamrcarvalho@hotmail.com

<sup>2</sup> Profa. Doutora, Faculdade de Engenharia Agrícola – UNICAMP, Fone: (19) 3521-1085, daniella.moura@feagri.unicamp.br

<sup>3</sup> Mestre, Faculdade de Engenharia Agrícola – UNICAMP, Fone: (19) 3521-1026, jujumassari@hotmail.com

<sup>4</sup> Mestre, Faculdade de Engenharia Agrícola – UNICAMP, Fone: (19) 3521-1026, rimena.vercellino@gmail.com

<sup>5</sup> Mestre, Faculdade de Engenharia Agrícola – UNICAMP, Fone: (19) 3521-1026, Luana\_as@hotmail.com

Apresentado no

XLIII Congresso Brasileiro de Engenharia Agrícola - CONBEA 2014  
27 a 31 de julho de 2014- Campo Grande- MS, Brasil

**RESUMO:** A necessidade do controle efetivo do ambiente interno das instalações animais é a principal razão do uso de diferentes modelagens computacionais visando detectar falhas decorrentes do projeto em aviários de frango de corte. O objetivo deste estudo foi desenvolver uma metodologia para construção de modelos de predição da vazão ideal por meio de redes neurais. O modelo foi construído levando em consideração dados térmicos externos e térmicos e aéreos internos de quatro aviários (*Blue House/BH*, *Dark House/DH*, *Double Wide House/DWH* e *Solid Wall/SW*) com sistema de ventilação artificial de pressão negativa. O modelo de redes neurais foi construído utilizando o algoritmo *backpropagation* no programa WEKA<sup>®</sup>. Todos os aviários necessitam de intensificação do sistema de ventilação, auxiliando na manutenção das condições internas ideais e por consequência melhor desempenho das aves. O modelo de redes neurais apresentou erro relativo absoluto de 1,1726%, 0,9436%, 0,7822% e 3,5006% para os aviários BH, DH, DWH e SW, respectivamente. As redes neurais artificiais foram capazes de auxiliar a tomada de decisão quanto da vazão de ar dos exaustores necessária para renovação e resfriamento do ar nas instalações de frango de corte levando em consideração parâmetros internos e externos ao aviário.

**PALAVRAS-CHAVE:** Controle ambiental, Sistema de ventilação, Inteligência Artificial

### NEURAL NETWORK FOR IDEAL EXHAUST FLOW PREDICTION IN TUNNEL VENTILATED BROILER HOUSES WITH DIFFERENT TYPOLOGIES

**ABSTRACT:** The requirement of environment effective control in rural facilities is the main reason why different computational modelling has been used to detect project's errors, especially in broiler houses. The aim of this study was to develop a methodology for models construction to ideal flow prediction by neural networks. The model considered the outside and inside aerial and thermal data of four tunnel ventilated broiler houses (*Blue House / BH*, *Dark House / DH*, *Double Wide House / DWH* and *Solid Wall / SW*). The neural network model was built using the backpropagation algorithm by WEKA<sup>®</sup> software. The model showed absolute relative error of 1,1726%, 0,7822% and 3,5006% for BH, DH, DWH and SW, respectively. As a conclusion, the neural networks models were able to assist the decision making related to the air renewal and air cooling requirement of air flow rate of the exhaust fans, taking into account the external and internal broiler houses' parameters.

**KEYWORDS:** environmental control, ventilation systems, artificial intelligence

## INTRODUÇÃO

A produção de frango de corte brasileira vem se desenvolvendo em um cenário muito competitivo. A produção mundial de carne de frango foi de 82.317 toneladas em 2012, sendo que o Brasil representa 15,36% da produção mundial e, a carne de frango responde por 1,50% do Produto Interno Bruto nacional. O Brasil apresentou crescimento de 111,37% entre o período de 2000 e 2012 e, ocupa o primeiro lugar no ranking mundial de maior exportador (3.918 toneladas de carne de frango) e o terceiro lugar como maior produtor de carne de frangos (12.645 toneladas de carne), sendo a região sudeste responsável por 11,70% da produção nacional e o estado de São Paulo é o mais representativo com 181.431 mil toneladas (UBABEF, 2013).

A avicultura de corte tem buscado o progresso por meio de pesquisas nas áreas de genética, instalações, nutrição, manejo, sanidade e conforto ambiental. Todos esses estudos têm como propósito, compreender melhor os fatores que influenciam o desenvolvimento e o desempenho de frangos de corte para que se obtenha a máxima produção de carne com o menor custo de produção, considerando simultaneamente, o bem estar das aves, possibilitando condições adequadas para expressar suas melhores características produtivas (NAZARENO et al., 2009).

Dentre os diversos fatores que influenciam a produção de frangos de corte, os fatores ambientais, como a temperatura, umidade relativa, ventilação, iluminância, radiação entre outros, assumem relevante importância no processo de criação dos animais, pois são os que mais os afetam, sendo capazes de comprometer a função vital mais importante das aves, que é a homeotermia (OLIVEIRA et al., 2006; AMARAL et al., 2011). É sabido que os animais atingem a sua produtividade ótima quando são mantidos em ambiente termoneutro, ou seja, quando a energia do alimento não é desviada para compensar desvios térmicos em relação ao intervalo de termoneutralidade para eliminar ou manter o seu calor.

Neste contexto, a necessidade do controle e entendimento efetivo do ambiente interno nas instalações avícolas é a principal razão do uso de diferentes métodos matemático e computacionais (ROUSH et al., 1996; KIRCHNER et al., 2004; ZHANG et al., 2005; VALE et al., 2008; LIMA & RODRIGUES, 2010). As simulações são importantes para a previsão de problemas localizados, auxiliando na implantação de procedimentos de controle, com o objetivo de reduzir perdas produtivas. As Redes Neurais Artificiais (RNAs) são ferramentas de Inteligência Artificial que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência, ela se adapta e aprende a realizar certa tarefa, ou comportamento, a partir de um conjunto de exemplos dados. A aplicação das RNAs torna-se bastante interessante em relação às características deste tipo de ferramentas, tais como: robustez, generalização, paralelismo e tolerância ao ruído.

Assim, o objetivo deste estudo foi desenvolver uma metodologia para construção de modelos de predição da vazão ideal por meio de redes neurais.

## MATERIAL E MÉTODOS

- Descrição dos aviários:

O presente trabalho foi conduzido em três aviários comerciais localizados na região de Amparo-SP com clima Cwa com duas estações bem definidas (conforme classificação de Köppen).

O registro dos dados foi realizado semanalmente quando as aves da linhagem Cobb Vantress 500 apresentavam 21, 28, 35 e 42 dias de idade, às 9h00min e 14h00min, no período de verão e inverno.

O aviário do tipo *Blue House* (BH) estava localizado em Amparo-SP (latitude 22°45'43" sul, longitude 46°47'43" oeste, altitude de 706 m), com orientação cartográfica noroeste-sudeste, dimensões de 17,00 x 90,00 x 2,45 m (largura x comprimento x pé-direito) e densidade de 15 aves m<sup>-2</sup>. O sistema de ventilação era artificial de pressão negativa contendo dez exaustores, com

diâmetro de 1,38m, hélice com três pás e motor de 1 CV e vazão nominal de 38.000 m<sup>3</sup> h<sup>-1</sup> (pressão de 0 Pa), sem uso de painel evaporativo e vedação com cortinas laterais na cor azul na face interna e prata na face externa (Figura 1 a).

O aviário do tipo *Dark House* (DH) estava localizado em Amparo-SP (latitude 22°44'01" sul, longitude 46°44'02" oeste, altitude de 706 m), com orientação cartográfica noroeste-sudeste, dimensões de 20,00 x 150,00 x 2,90 m (largura x comprimento x pé-direito) e densidade de 12 aves m<sup>-2</sup>. O sistema de ventilação era artificial de pressão negativa contendo dezesseis exaustores, com diâmetro de 1,30 m, hélice com três pás e motor de 1,50 CV e vazão nominal de 38.000 m<sup>3</sup> h<sup>-1</sup> (pressão de 0 Pa), com uso de painel evaporativo feito de tijolo cerâmico e vedação com cortinas laterais na cor preta na face interna e prata na face externa (Figura 1 b).

O aviário do tipo *Double Wide House* (DWH) estava localizado em Socorro-SP (latitude 22°35'29" sul, longitude 46°31'44" oeste, altitude de 706 m), com orientação cartográfica noroeste-sudeste, dimensões de 24,5 x 160,0 x 2,4 m (largura x comprimento x pé-direito) e densidade de 12 aves m<sup>-2</sup>. O sistema de ventilação era artificial de pressão negativa contendo dezesseis exaustores, com diâmetro de 1,30 m, hélice com três pás e motor de 1,50 CV e vazão nominal de 50.460 m<sup>3</sup> h<sup>-1</sup> (pressão de 0 Pa), com uso de painel evaporativo feito de celulose e vedação com cortinas laterais na cor preta na face interna e prata na face externa (Figura 1 c).

O aviário do tipo *Solid Wall* (SW) estava localizado em Amparo-SP (latitude 22°45'37" sul, longitude 46°46'42" oeste, altitude de 706 m), com orientação cartográfica norte-sul, dimensões de 20 x 120 x 3 m (largura x comprimento x pé-direito) e densidade de 13 aves m<sup>-2</sup>. O sistema de ventilação era artificial de pressão negativa contendo dezesseis exaustores, com diâmetro de 1,38 m, hélice com três pás e motor de 1,0 CV e vazão nominal de 41.100 m<sup>3</sup> h<sup>-1</sup> (pressão de 0 Pa), com uso de painel evaporativo feito de celulose e vedação de alvenaria com parede de bloco de concreto (Figura 1 d).




Figura 1. Aviário do tipo *Blue House* (a), *Dark House* (b), *Double Wide House* (c) e *Solid Wall* (d).

- Aquisição dos dados:

O registro dos dados de temperatura (T<sub>bs</sub>, °C) e velocidade do ar (Var, m s<sup>-1</sup>) foi realizado por meio de um anemômetro de fio quente VelociCalc<sup>®</sup> (TSI<sub>TM</sub>), com escala de leitura para temperatura de -18 a 93 °C e resolução 0,1 °C, e velocidade do ar com amplitude de 0 a 30 m s<sup>-1</sup>, resolução de velocidade de 0,01 m s<sup>-1</sup> e exatidão de ± 0,015 m s<sup>-1</sup>. Para os dados de umidade relativa (UR, %) foram coletados por meio do equipamento THDL 400 (Instrument<sup>®</sup>), com amplitude de 25 a 95% e precisão de ±5%. Os dados de concentração de amônia (NH<sub>3</sub>, ppm) e concentração de dióxido de carbono (CO<sub>2</sub>, ppm) foram registrados por meio de um medidor instantâneo de concentração de gases GasAlertMicro 5, BW Technologies<sup>®</sup>. Os dados da temperatura e umidade relativa externa aos aviários foram registradas por meio de um datalogger HOBO<sup>®</sup> (ONSET).

Nos dados de temperatura de bulbo seco e umidade relativa foram realizadas correções numéricas adaptado da metodologia proposta por BARBOSA FILHO et al. (2009) em que consiste em corrigir a defasagem de tempo entre a coleta do dado no primeiro e último ponto em decorrência da coleta manual dos dados. As variáveis ambientais foram registradas na altura das aves (0,30 m do piso), em 52 pontos distintos e equidistantes, para posterior modelagem (Figura 2).




Figura 2. Distribuição dos 52 pontos de registro das variáveis ambientais, na altura das aves.

- Análise dos dados:

As redes neurais foram utilizadas na proposta de um novo modelo de controle do sistema de ventilação dos galpões estudados, tendo como base o alcance da vazão ideal para os exaustores.

O método para obter novos valores da vazão foi implementado por meio do software Weka<sup>®</sup> 3.6.9 redes neurais de retropropagação muito utilizado para sistemas de predição conhecido como *feedforward-backpropagation* (SANZOGNI & KERR, 2001). Para a construção e validação do modelo, foi utilizado o teste Cross-validation 10 folds. A vazão recomendada pelo modelo foi obtida inserindo banco de dados com os valores dos erros iguais à zero e a vazão sem valor algum, pelo teste *Supplied Test Set*.

A rede apresenta topologia configurada em três camadas, sendo 15 neurônios na camada de entrada, oito neurônios na camada oculta e um neurônio na camada de saída.

Foram construídos cinco bancos de dados para cada tipo de aviário, sendo um banco de dados para a construção e validação do modelo e os outros quatro bancos de dados para a identificação de novos valores de vazão dos exaustores. Os bancos de dados apresentavam as seguintes variáveis de entrada: Tbs\_int – temperatura de bulbo seco no interior do aviário, UR\_int – umidade relativa no interior do aviário, Tbs\_ext – temperatura de bulbo seco no exterior do aviário, UR\_ext – umidade relativa no exterior do aviário, Var\_int – velocidade do ar no interior do aviário, CO<sub>2</sub>\_int – concentração de dióxido de carbono no interior do aviário, NH<sub>3</sub>\_int – concentração de amônia no interior do aviário, Erro\_Tbs – diferença entre a temperatura interna no aviário e a temperatura ideal para cada fase da ave, Erro\_UR – diferença entre a umidade interna no aviário e a umidade ideal para cada fase da ave, Erro\_Var – diferença entre a velocidade do ar interna no aviário e a velocidade do ar ideal para a cada fase da ave, Erro\_NH<sub>3</sub> – diferença entre a concentração de amônia interna no aviário e a concentração de amônia ideal para cada fase da ave, Erro\_CO<sub>2</sub> – diferença entre a concentração de dióxido de carbono interna no aviário e a concentração de dióxido de carbono ideal para cada fase da ave e como variável de saída a Vazão – somatória de todas as vazões dos exaustores acionados no momento da coleta de dados.

O modelo foi construído e validado, pelo teste *cross-validation (10 folds)*, baseado no banco de dados com variáveis registradas no interior e exterior do aviário. Este modelo é a representação de um banco de dados em função dos aviários estudados.

A rede utilizada neste trabalho foi escolhida pela eficiência *Feedforward-backpropagation* ser satisfatória (WHANG & ELHAG, 2007) e os modelos obtidos foram avaliados pelos parâmetros: coeficiente de correlação, erro médio absoluto, raiz quadrada do erro quadrático médio, erro relativo absoluto e raiz quadrada do erro quadrático relativo.

## RESULTADOS E DISCUSSÃO

A taxa de aprendizado (onde os pesos sinápticos são atualizados) escolhida foi de 0,3, o momento (momento aplicado aos pesos sinápticos durante a atualização) de 0,2, devido à baixa complexibilidade do modelo foi utilizado 500 épocas para treinar o modelo, ou seja, o número de vezes em que o conjunto de treinamento foi apresentado à rede. Como citado por Pandorfi et al. (2011), redes neurais do tipo Multi Layer Perceptron (MLP) apresentou dificuldades na definição dos seus parâmetros, entretanto sua arquitetura apresenta maior sensibilidade.

Os coeficientes de determinação obtidos pela relação funcional entre a vazão medida e a vazão estimada próximo do valor de 1,0 reforça que as variáveis de entrada podem ser utilizadas para predição da vazão dos exaustores (Figura 3).

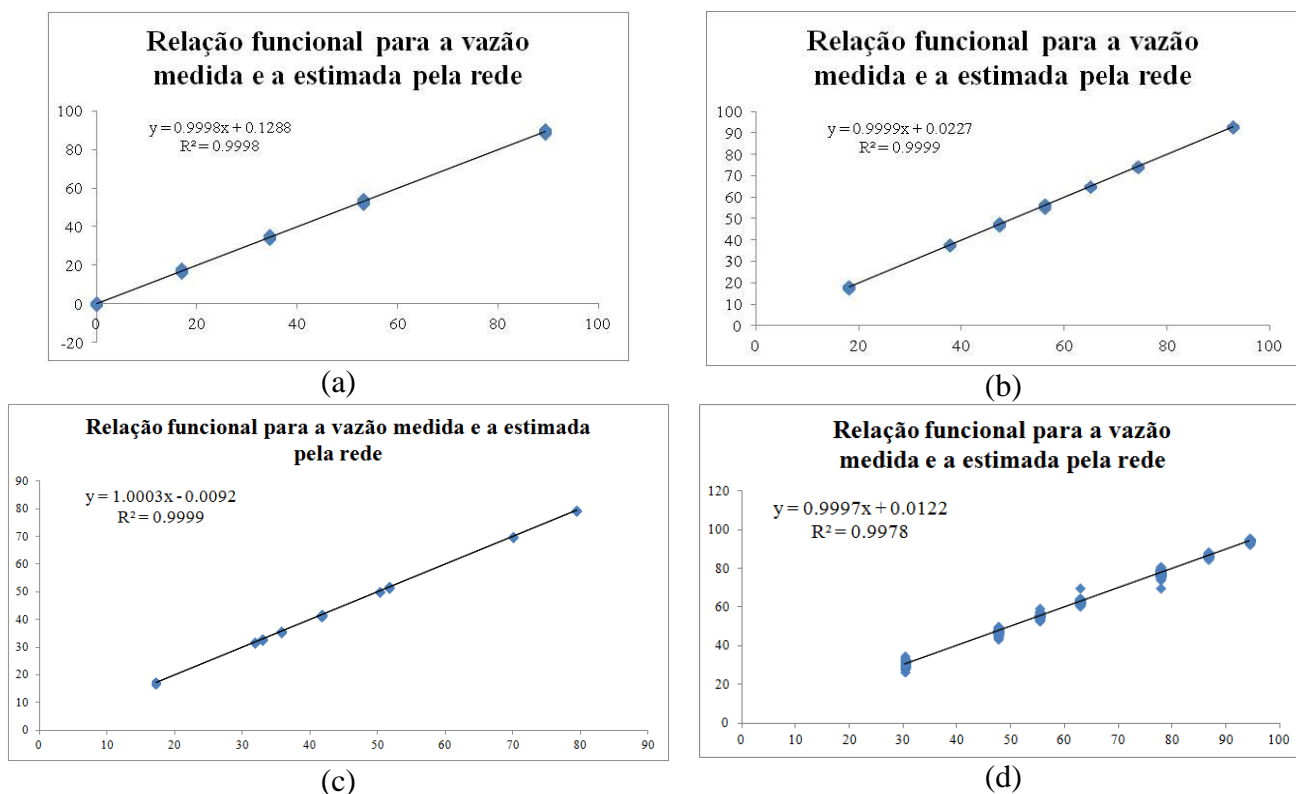


Figura 1. Relação funcional para a vazão medida e a estimada pela rede neural relacionadas aos aviários *Blue House* (a), *Dark House* (b), *Double Wide House* (c) e *Solid Wall* (d).

As redes neurais artificiais foram capazes de auxiliar na tomada de decisão em relação à vazão necessária para manutenção das variáveis climáticas e aéreas no interior do aviário em níveis adequados levando-se em consideração as condições externas. Desta forma, o modelo pode auxiliar o controlador na identificação de quantos exaustores deveriam ser acionados para manter as aves em conforto térmico. Neste sentido, os modelos baseados em redes neurais inferiram que o aviário BH deveria aumentar a vazão dos exaustores em 92,42% dos casos (Figura 4), o aviário DH deveria aumentar a vazão dos exaustores em 1,48% dos casos (Figura 5), o aviário DWH deveria diminuir a vazão dos exaustores em 22,72% dos casos (Figura 6) e, por fim o aviário SW deveria diminuir a vazão dos exaustores em 19,59% dos casos (Figura 7).




Figura 2. Variação entre a vazão medida e a estimada pelo modelo de rede neural utilizada no banco

de dados (erro da predição neste banco de dados igual à 0,0000622).




Figura 5. Variação entre a vazão medida e a estimada pelo modelo de rede neural utilizada no banco de dados (erro da predição neste banco de dados igual à 0,0000117).

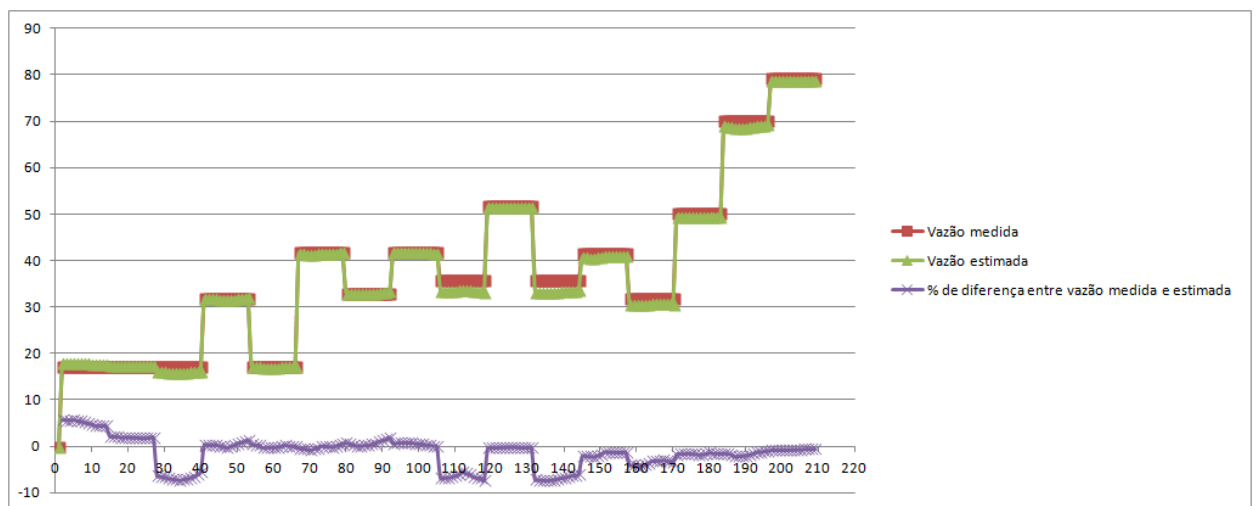


Figura 6. Variação entre a vazão medida e a estimada pelo modelo de rede neural utilizada no banco de dados (erro da predição neste banco de dados igual à 0,0000132).

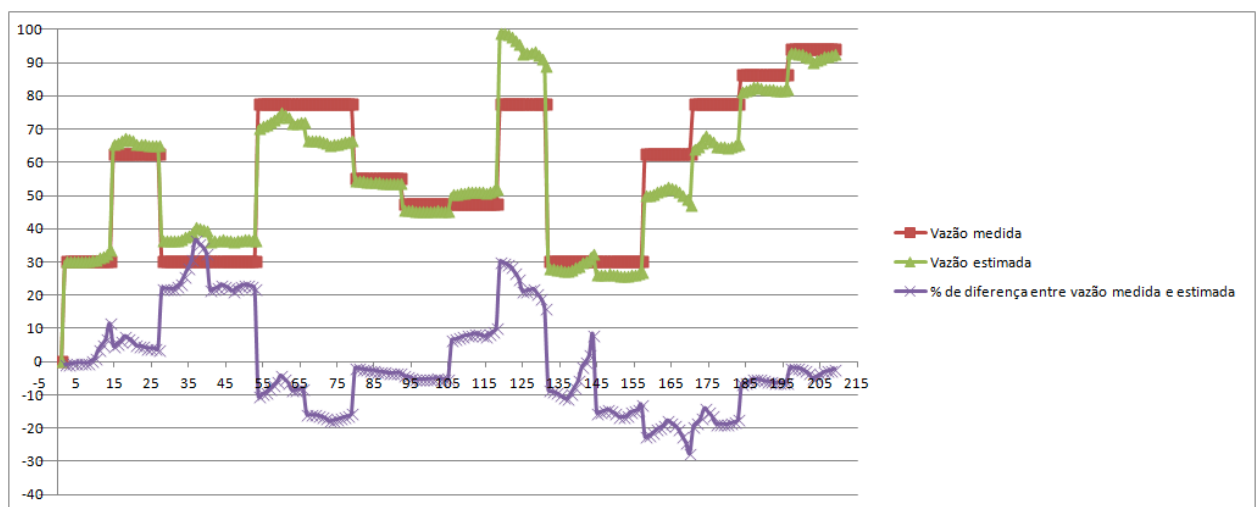


Figura 7. Variação entre a vazão medida e a estimada pelo modelo de rede neural utilizada no banco de dados (erro da predição neste banco de dados igual à 0,0005138).



## CONCLUSÕES

As redes neurais artificiais são capazes de auxiliar a tomada de decisão quanto da vazão de ar dos exaustores necessária para renovação e resfriamento do ar nas instalações de frango de corte, em função das condições climáticas internas e externas, em comparação com as condições ideais para a criação de aves alojadas de acordo com a idade das mesmas. Esta técnica limita-se ao universo de dados que é fornecido ao programa para construção do modelo, neste sentido quanto maior o número de dados, melhor é a inferência do modelo.

## REFERÊNCIAS

- AMARAL, A.G. et al. Effect of the production environment on sexed broilers reared in a commercial house. **Arq. Bras. Med. Vet. Zootec.**, v.63, n.3, p.649-658, 2011.
- KIRCHNER, K.; TÖLLE, K.H.; KRIETER, J. Decision tree technique to pig farming datasets. **Livestock Production Science**, n.90, p.191-200, 2004.
- LIMA, M.G.F.; RODRIGUES, L.H.A. Árvore de decisão aplicada em dados de incubação de matrizes de postura hy-line W36. **Ciênc. Agrotec.**, v.34, n.6, p.1550-1556, 2010.
- NAZARENO, A.C. et al. Avaliação do conforto térmico e desempenho de frangos de corte sob regime de criação diferenciado. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.13, n.6, p.802-808, 2009.
- OLIVEIRA, L.M. et al. Zoneamento bioclimático da região Sudeste do Brasil para o conforto térmico animal e humano. **Engenharia Agrícola**, v.26, p.823-831, 2006.
- PANDORFI, H. et al. Uso de redes neurais artificiais para predição de índices zootécnicos nas fases de gestação e maternidade na suinocultura. **R. Bras. Zootec.**, v.40, n.3, 2011.
- ROUSH, W.B. et al. Probabilistic neural network prediction of ascites in broiler based on minimally invasive physiological factors. **Poultry Science**, v.76, p.1513-1516, 1996.
- SANZOGNI, L.; KERR, D. Milk production estimates using feed forward artificial neural networks. *Computers and Electronics in Agriculture*, London, V.32, p. 21-30, 2001.
- UBABEF – União Brasileira de Avicultura. **Relatório Anual 2012**. Disponível: <<http://www.ubabef.com.br/estatisticas/frango>>. Acesso em: 20/10/2013.
- VALE, M.M. et al. Data mining to estimate broiler mortality when exposed to heat wave. **Scientia Agrícola**, v.65, p.335-339, 2008.
- WHANG, Y.M.; ELHAD, T.M.S. A comparison of neural network, evidential reasoning and multiple regression analysis in modelling bridge risks. **Expert Systems with Applications**, v.32, p.336-348, 2007.
- ZHANG, B.; VALENTINE, I.; KEMP, P. Modelling the productivity of naturalized pasture in the North Island, New Zealand: a decision tree approach. **Ecological Modelling**, v.186, p.299-311, 2005.