



KLEBER DE ALMEIDA CARVALHO

**INTELIGÊNCIA ARTIFICIAL APLICADA À PREDIÇÃO DA
TEMPERATURA SUPERFICIAL DE FRANGOS DE CORTE**

LAVRAS – MG

2017

KLEBER DE ALMEIDA CARVALHO

**INTELIGÊNCIA ARTIFICIAL APLICADA À PREDIÇÃO DA TEMPERATURA
SUPERFICIAL DE FRANGOS DE CORTE**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Engenharia de Sistemas e Automação, para a obtenção do título de Mestre.

Prof. Dr. Tadayuki Yanagi Junior

Orientador

Prof. Dr. Wilian Soares Lacerda

Profa. Dr. Patrícia Ferreira Ponciano Ferraz

Prof. Dr. Lucas Henrique Pedrozo Abreu

Prof. Dr. Alessandro Torres Campos

Co-orientadores

LAVRAS – MG

2017

Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).

de Almeida Carvalho, Kleber .

Inteligência artificial aplicada à predição da temperatura
superficial de frangos de corte / Kleber de Almeida Carvalho. -
2017.

47 p.

Orientador(a): Tadayuki Yanagi Junior.

Dissertação (mestrado acadêmico) - Universidade Federal de
Lavras, 2017.

Bibliografia.

1. Redes neurais artificiais. 2. Termografia infravermelha. 3.
Avicultura. I. Yanagi Junior, Tadayuki. . II. Título.

KLEBER DE ALMEIDA CARVALHO

**INTELIGÊNCIA ARTIFICIAL APLICADA À PREDIÇÃO DA TEMPERATURA
SUPERFICIAL DE FRANGOS DE CORTE**

**ARTIFICIAL INTELLIGENCE APPLIED TO THE PREDICTION OF BROILER'
SURFACE TEMPERATURE**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Engenharia de Sistemas e Automação, para a obtenção do título de Mestre.

APROVADA em 24 de agosto de 2017.

Dr. Danton Diego Ferreira (DEG/UFLA)

Dra. Késia Oliveira da Silva Miranda (Esalq/USP)

Dra. Joelma Rezende Durão Pereira (UNILAVRAS)

Prof. Dr. Tadayuki Yanagi Junior
Orientador

Prof. Dr. Wilian Soares Lacerda
Profa. Dra. Patrícia Ferreira Ponciano Ferraz
Prof. Dr. Lucas Henrique Pedrozo Abreu
Prof. Dr. Alessandro Torres Campos
Co-orientadores

LAVRAS – MG

2017

A Deus. À minha mãe, Elvira Dorotéa de Almeida Carvalho, pelo amor, compreensão, conselhos e apoio em todos os momentos da minha vida e ao meu pai José Fabiano de Carvalho. À minha irmã Karen de Almeida Carvalho. Dedico

AGRADECIMENTOS

À Universidade Federal de Lavras (UFLA) e ao Departamento de Engenharia (DEG), pela oportunidade de realizar o mestrado;

Ao professor *DSc.* Tadayuki Yanagi Junior, pela orientação, paciência, apoio e conhecimentos passados;

À Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) pela concessão da bolsa de estudos;

Aos professores *DSc.* Patrícia Ferreira Ponciano Ferraz e *DSc.* Lucas Henrique Pedrozo Abreu pela coorientação;

Aos professores e funcionários do Departamento de Engenharia da UFLA;

Aos amigos, colegas e minha família.

RESUMO

Frangos de corte na fase inicial de criação não possuem o sistema termorregulador totalmente desenvolvido e, se nesta fase forem submetidos a condições de desconforto térmico terão o desempenho reduzido. A temperatura superficial (Ts) é uma resposta fisiológica, não invasiva, no qual o animal pode ser considerado como um biosensor. Desta forma, objetivou-se com a presente pesquisa desenvolver um modelo baseado em redes neurais artificiais para prever a Ts de frangos de corte. Para treinar e validar 100 redes neurais utilizou-se de um banco de dados, com 630 registros, que foi aleatoriamente dividido para o treinamento (70%), teste (15%) e validação (15%). Posteriormente, a rede com melhor desempenho foi escolhida. Para o desenvolvimento das RNAs as variáveis de entrada foram a idade das aves (I) e a temperatura do ar (Tar), e a variável de saída a Ts. As RNAs desenvolvidas adotaram a arquitetura *multilayer-perceptron* (MLP) com uma camada de entrada, uma camada escondida (oculta ou intermediária) e uma de saída. A melhor rede é capaz de prever com alta confiabilidade a Ts de frangos de corte jovens uma vez que foi obtido um coeficiente de determinação (R^2) na validação de 0,9118. Com os dados característicos da melhor rede, incluindo os pesos dos neurônios, é possível o desenvolvimento de *softwares* que podem ser embarcados em controladores, a fim de se controlar o ambiente térmico no interior de aviários comerciais para criação de frangos de corte.

Palavras-chave: Redes neurais artificiais, termografia infravermelha, avicultura.

ABSTRACT

Broiler chickens in the initial growing stage do not have the thermoregulatory system fully developed and, if at this stage they are submitted to thermal discomfort conditions, the performance will be reduced. Surface temperature (T_s) is a physiological, non-invasive response in which the animal can be considered as a biosensor. Thus, the objective of this research was to develop a model based on artificial neural networks to predict the T_s of broiler chickens. To train and validate 100 neural networks, a database with 630 registers was randomly divided for training (70%), test (15%) and validation (15%). Subsequently, the best performing network was chosen. For the development of the RNAs, the input variables were the age of the birds (I) and the air temperature (T_{ar}), and the output variable T_s . The developed RNAs adopted multilayer-perceptron (MLP) architecture with an input layer, a hidden layer and an output layer. The best network is able to predict with high reliability the T_s of young broiler chickens once a coefficient of determination (R^2) of 0.9118 was obtained in the validation phase. With the characteristics of the best network, including the neuronal weights, it is possible to develop software that can be shipped in controllers, in order to control the thermal environment inside commercial broiler houses.

Keywords: Artificial neural networks, infrared thermography, poultry production

SUMÁRIO

	PRIMEIRA PARTE.....	10
1	INTRODUÇÃO.....	10
2	OBJETIVOS.....	11
2.1	Objetivos específicos	11
3	HIPÓTESE.....	11
4	REVISÃO DE LITERATURA.....	12
4.1	Ambiente térmico.....	12
4.2	Sistemas de aquecimento.....	13
4.3	Respostas fisiológicas.....	13
4.4	Desempenho produtivo.....	14
4.5	Inteligência artificial.....	15
4.5.1	Redes neurais artificiais.....	15
4.5.2	Lógica <i>fuzzy</i>.....	18
4.6	Controle do ambiente térmico de produção.....	20
5	CONSIDERAÇÕES FINAIS.....	21
6	REFERÊNCIAS BIBLIOGRÁFICAS.....	21
	SEGUNDA PARTE – ARTIGO.....	26
	ARTIGO 1 - Redes neurais artificiais aplicadas à predição da temperatura superficial de frangos de corte jovens.....	26

PRIMEIRA PARTE

1 INTRODUÇÃO

A produção brasileira de frangos de corte tem papel importante na economia nacional uma vez que além de atender ao mercado interno é responsável por excelentes resultados na exportação. Em 2016, a produção mundial de frangos de corte foi de 88.718 milhões de toneladas, tendo o Brasil contribuído com 12.900 milhões de toneladas, ficando atrás apenas dos EUA (ABPA, 2017).

No ano de 2016, as exportações de carne de frango chegaram a 34% da produção total de frangos no Brasil. O consumo interno ficou em 66% e o consumo per capita foi de 41,10 kg hab⁻¹, constituindo em aumento de aproximadamente 11,02% em relação ao ano de 2007 (ABPA, 2017).

Apesar dos avanços obtidos em relação à genética, nutrição e sanidade, o ambiente térmico influencia diretamente a expressão do potencial genético das aves. Nas primeiras semanas de vida os frangos de corte, apesar de serem animais homeotérmicos, ainda não possuem o sistema termorregulador plenamente desenvolvido. Desta forma, se forem submetidos a condições de estresse térmico, o desenvolvimento será afetado e poderá não ser recuperado ao longo do ciclo produtivo.

Como forma de se avaliar os efeitos das condições térmicas no ambiente de produção sobre os animais pode-se avaliar uma ou mais respostas fisiológicas. Dentre estas respostas, destaca-se a temperatura superficial das aves, devido a fácil mensuração, e por constituir em uma forma não invasiva.

Considerando ainda, a quantidade de incertezas relacionadas ao sistema de produção de frangos de corte, a aplicação da inteligência artificial como forma de se obter modelos para controle do ambiente térmico de produção pode auxiliar na tomada de decisão em relação ao acionamento de sistemas de aquecimento na fase inicial de criação, propicia o aumento do desempenho produtivo.

2 OBJETIVOS GERAIS

Desenvolver uma rede neural artificial (RNA) para predição da temperatura superficial (Ts) de frangos de corte

2.1 OBJETIVOS ESPECÍFICOS

- Treinar, testar e validar uma RNA para predição da Ts de frangos de corte em função da idade (do 1° ao 14° dias de idade) e da temperatura de bulbo seco do ar (Tar);
- Desenvolver um fluxograma para possibilitar a programação da RNA em uma linguagem computacional para posterior embarque em um sistema de controle do ambiente térmico.

3 HIPÓTESE

Apesar de serem homeotérmicos, os frangos de corte nas primeiras semanas de vida não são capazes de manter a sua temperatura corporal dentro dos limites adequados, quando submetidos a condições de estresse térmico, por meio de mecanismos fisiológicos e comportamentais, por não possuírem o seu sistema termorregulador completamente desenvolvido. Dessa forma, a hipótese da presente pesquisa é que a temperatura superficial de frangos de corte pode ser predita adequadamente por meio de uma rede neural artificial. Por se tratar de uma resposta direta da ave e ser medida de forma não invasiva, a sua predição e possível uso em controladores poderá propiciar o melhor controle do microclima para a criação destas aves.

4 REVISÃO DE LITERATURA

O ambiente térmico no interior de aviários influencia diretamente as respostas fisiológicas e produtivas dos frangos de corte, especialmente nas primeiras semanas de vida nas quais os pintinhos não possuem o sistema termorregulador completamente desenvolvido. Neste contexto, o desenvolvimento e uso de algoritmo embarcado em um sistema de aquisição e controle para o controle do ambiente térmico no interior do aviário torna-se importante. Dentre os algoritmos a serem embarcados destacam-se aqueles baseados em inteligência artificial, como a lógica *fuzzy* e as redes neurais artificiais.

4.1 Ambiente térmico

Na avicultura moderna, os altos padrões de produção e produtividade alcançados devem principalmente aos avanços na genética, nutrição, sanidade, manejo e no ambiente de produção. Neste contexto, o ambiente térmico afeta diretamente o desempenho animal (MOURA et al., 2006; SALGADO et al., 2007; TEIXEIRA et al., 2009; NAZARENO et al., 2009; CORDEIRO et al., 2010; MENEGALI et al., 2010; BARACHO et al., 2013).

Por não terem o sistema termorregulatório totalmente desenvolvido, pintinhos precisam ser criados em ambiente com temperatura controlada nas primeiras duas semanas de vida (MENEGALI et al., 2013), sendo assim, o aquecimento se faz necessário. As condições térmicas às quais as aves são submetidas nas duas primeiras semanas de vida são importantes para o desenvolvimento futuro do animal. Assim, torna-se necessário realizar o monitoramento das instalações para o controle do ambiente térmico uma vez que fatores térmicos podem comprometer a homeotermia das aves (OLIVEIRA et al., 2006).

No Brasil, as fomalhas ainda são as fontes de calor mais utilizadas, contudo podem não ser estáveis e não fornecer a temperatura adequada (MENEGALI et al., 2013). Desta forma, propiciar um ambiente de criação adequado às necessidades das aves contribui para a melhoria das condições de bem-estar, melhorando, assim, sua produtividade (TINÔCO; FIGUEIREDO; SANTOS, 2004).

Para melhor desempenho das aves, vários autores procuram estabelecer temperaturas de bulbo seco do ar ideais para o ambiente de criação. Essas temperaturas são classificadas em intervalos definidos por limites inferiores e superiores, considerando as diferentes idades das aves (Tabela 1).

Tabela 1 – Limites inferiores e superiores das temperaturas do ar ideais de criação de frangos de corte em diferentes semanas de vida.

Semana	Limites de temperatura do ar (°C)
Primeira	34 – 32
Segunda	32 – 28
Terceira	28 – 26

Fonte: Adaptado de CASSUCE (2011), CLARK (1981), FREEMAN (1968), MAY e LOT (2000), MEDEIROS et al. (2005) e YOUSEF (1985).

4.2 Sistemas de aquecimento

A avicultura é um setor da economia brasileira de bastante destaque. E o Brasil posiciona-se como grande produtor e exportador mundial de carne de frango. Muita pesquisa e investimento são feitos a favor de uma maior produtividade e, neste sentido, sistemas de aquecimento são fundamentais no processo de produção de frangos de corte. Como fatores decisivos na escolha do melhor método para aquecimento de aviários consideram-se a eficiência energética, o custo da energia, o custo de equipamentos e os impactos ambientais. Assim, a escolha inadequada dos mecanismos e sistemas de aquecimento pode impactar negativamente a produtividade. Desta forma, decisões relacionadas ao investimento podem afetar diretamente a rentabilidade esperada (COLLATTO et al., 2015).

Segundo Cordeiro et al. (2010), geralmente os sistemas de aquecimento se baseiam na queima de combustível, liberando gases danosos às aves, aos trabalhadores e à atmosfera.

Dentre os sistemas de aquecimento destacam-se fornalha a carvão vegetal, campânulas infravermelhas a gás, tambores de aquecimento por radiação, energia elétrica e piso aquecido. Sistema auxiliar de aquecimento baseado em energia solar também tem sido estudado (CAMPOS et al., 2013).

4.3 Respostas fisiológicas

As respostas fisiológicas dos animais servem como parâmetro para avaliação do conforto térmico e da qualidade das condições de criação das aves (PONCIANO et al., 2012). De acordo com a literatura, dentre as respostas fisiológicas avaliadas em estudos envolvendo ambiência animal, destacam-se a temperatura cloacal, a frequência respiratória e a temperatura superficial das aves.

Para manter a temperatura corporal aproximadamente constante nos intervalos de conforto para cada faixa etária, o frango de corte deverá controlar o ganho ou perda de calor em resposta às mudanças do ambiente térmico (FUNCK e FONSECA, 2008). Este controle

pode ser obtido por meio de mecanismos comportamentais e fisiológicos (FURTADO et al., 2010). O aumento da temperatura cloacal é uma das respostas do animal às condições de altos valores de temperatura e umidade relativa do ar (SILVA et al., 2003).

A frequência respiratória, comparada à temperatura cloacal, em termos de avaliação do conforto ou desconforto térmico, possui a vantagem de ser uma resposta que se manifesta em menor tempo. Além disso, a temperatura cloacal é de difícil mensuração em condições de produção comercial. A frequência respiratória dos animais aumenta quando estes são submetidos ao estresse por altas temperaturas (BORGES et al., 2003). Este aumento propicia a dissipação de calor de forma eficiente, estimulando as perdas evaporativas a fim de manter o equilíbrio térmico do corpo do animal (OLIVEIRA NETO et al., 2000).

Por sua vez, a temperatura superficial dos animais permite a avaliação de uma resposta fisiológica de forma não invasiva, não gerando estresse e propiciando fácil controle do sistema de aquecimento de aviário. A temperatura superficial, em dada condição térmica ao qual o animal está submetido, consiste no resultado do balanço de calor entre o animal e ambiente térmico ao seu redor.

4.4 Desempenho produtivo

O consumo de ração, ganho de peso, conversão alimentar e taxa de mortalidade têm sido usados para avaliar o desempenho produtivo de aves (VIGODERIS et al., 2010), bem como, para estudar os efeitos do ambiente sobre a produtividade destes animais. Valores de referência de alguns destes índices de desempenho estão associados à linhagem e podem ser obtidos nos manuais da linhagem (Tabela 2).

Tabela 2 – Metas de desempenho para frangos de corte da linhagem Cobb, criados em condições de conforto para aves mistas.

Semana de vida	Ganho de peso acumulado médio (g)	Conversão alimentar acumulada ($g\ g^{-1}$)	Consumo de ração acumulado diário (g)
Primeira	26,4	0,902	35
Segunda	32,2	1,1165	68
Terceira	44,9	1,264	111

Fonte: COBB-VANTRESS (2015).

Os frangos de corte quando submetidos a altos valores de temperatura e umidade relativa do ar reduzem o desempenho produtivo devido a alterações metabólicas além de prejudicar a manutenção da homeotermia (OLIVEIRA et al., 2006; TINÔCO, 2001), visando facilitar a

termorregulação. Similarmente, baixos valores de temperatura do ar também reduzem o desempenho produtivo de frangos de corte (CASSUCE, 2011), tendo em vista a necessidade de o organismo animal usar a energia disponível na ração para gerar calor ao invés de carne.

Em muitas regiões do Brasil, no inverno, o aquecimento ineficiente em conjunto com os fatores genéticos e nutricionais podem causar problemas no aparelho respiratório das aves, morte súbita e síndrome ascítica (ABREU et al., 2000). O estresse por baixas temperaturas, especialmente nos primeiros dias de vida do frango de corte, é danoso, pois nesta fase as aves não possuem sistema termorregulador plenamente desenvolvido (PONCIANO et al., 2012).

4.5 Inteligência artificial

A inteligência artificial é um campo de conhecimento que oferece modelos de apoio à decisão e ao controle com base em fatos reais e conhecimentos empíricos e teóricos (SELLITTO, 2002). A inteligência artificial se caracteriza pela capacidade de se programar em computador tarefas que o pensamento humano e animal são capazes de fazer naturalmente (MILLINGTON, 2006).

Os seres humanos são capazes de resolver problemas complexos, e, ao se criar métodos e sistemas que visam a solucionar tais problemas, de considerada complexidade, a partir da observação de sistemas existentes na natureza tem-se o que é denominado inteligência artificial.

A inteligência artificial: tem como desafio desenvolver sistemas de resolução de problemas que possam ser convertidos em modelos matemáticos e programas para uso em computadores ou controladores (COSTA, 2009). Como exemplos de inteligência artificial têm-se as redes neurais artificiais (RNAs) e a lógica *fuzzy*.

4.5.1 Redes neurais artificiais

Uma RNA imita o sistema neural biológico, sendo um mecanismo de aprendizado que tem como base o comportamento humano. Segundo Campos et al. (2010) o aprendizado pela experiência é uma característica de redes neurais artificiais. Tal aprendizado ocorre por meio dos chamados neurônios que compõem interligações controladas por pesos que são ajustados de acordo com padrões para determinadas saídas.

Segundo Oleskovicz et al. (2003), as RNAs podem ser do tipo *feedforward* ocorrendo em camadas cujo sentido da propagação da informação segue da camada de entrada para a saída, sem realimentação. Sendo que, ao se ter uma rede neural *feedforward* de no mínimo uma

camada intermediária pode-se utilizar do *backpropagation* como algoritmo de treinamento supervisionado. Neste algoritmo os pesos são corrigidos a partir da camada final até a inicial.

Segundo Fiorin et al. (2011), a forma como os pesos são ajustados caracteriza o algoritmo de treinamento de uma RNAs, que pode ser supervisionado ou não-supervisionado. Considerando-se o treinamento não-supervisionado tem-se que valores de entrada organizados em diferentes classes, mas com semelhanças em suas propriedades são apresentados a rede através do ajuste de pesos. Por sua vez, no treinamento supervisionado existe um comparador externo que avalia e ou fornece a rede valores de entrada quanto de saída esperados. Utiliza-se de forma bastante rotineira o algoritmo *backpropagation* como de treinamento supervisionado. Neste método, primeiramente gera-se uma saída a partir das entradas mantendo-se os pesos fixos. Posteriormente, gera-se um sinal de erro através da comparação das saídas, sendo este erro propagado da saída em direção a entrada e, assim, propiciando o ajuste dos pesos de forma a minimizar o erro.

Segundo Silva et al. (2012), dentre os algoritmos de aceleração destaca-se o algoritmo Levenberg-Marquardt. Com este algoritmo acelera-se e otimiza-se a convergência do algoritmo *backpropagation*. Em comparação com a técnica do gradiente descendente este algoritmo é mais eficiente. Este algoritmo usa de informações da segunda derivada da função do erro e, por isso, é um método de segunda ordem. Um problema observado com este método quando utilizado com RNAs muito grandes é o fato de potencialmente tornar-se computacionalmente impraticável. Contudo este método tem menor custo computacional que o método quase-Newton e é mais eficiente que o método do gradiente conjugado em RNAs com centenas de pesos.

Considerando-se um banco de dados apropriado, com unidades de processamento não lineares, as RNAs podem aprender a partir da experiência e estimar com acurácia uma relação funcional complexa (AZADEH et al., 2014), podendo desta forma, serem usadas em diversas áreas do conhecimento. A Figura 1 ilustra um neurônio genérico em uma rede MLP.

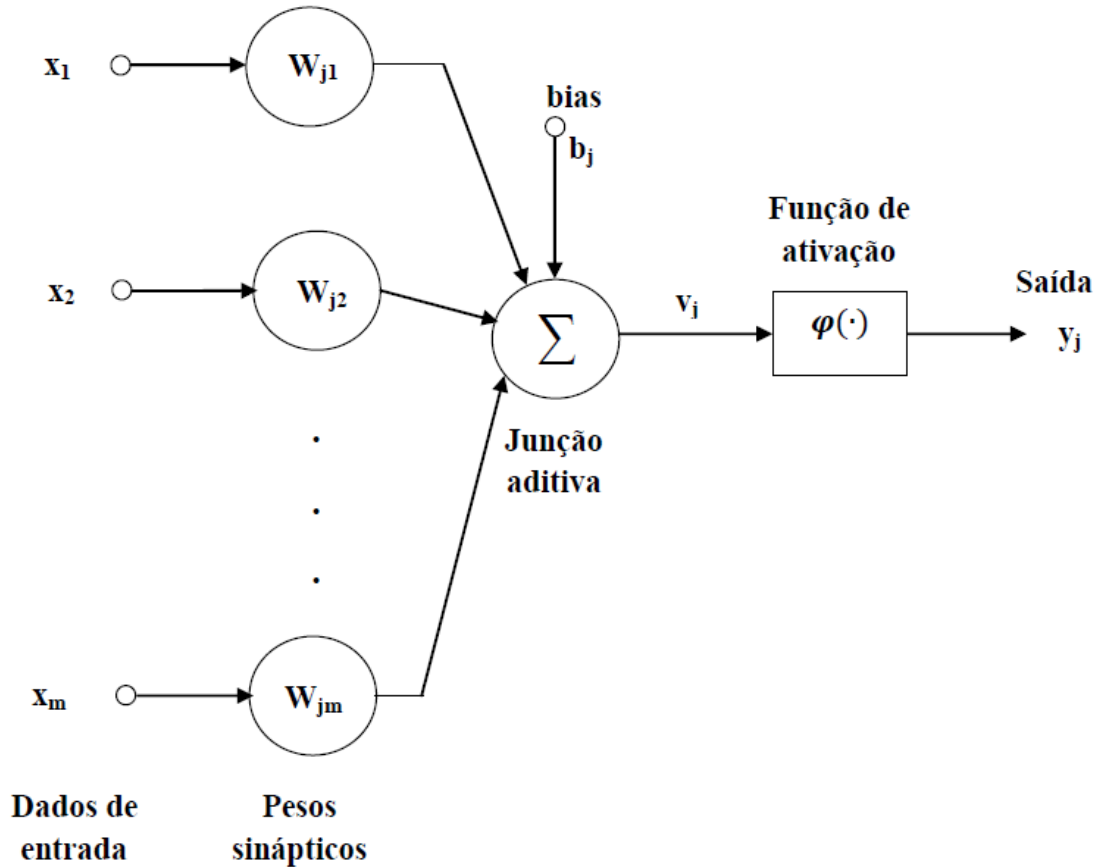


Figura 1. Representação gráfica de um neurônio artificial de uma rede *multilayer-perceptron* (MLP) com m variáveis de entrada (x_1, x_2, \dots, x_m) e uma de saída (y_j).

O nível de atividade interna de um neurônio (v_j) pode ser calculado pelo somatório ponderado dos valores de entrada adicionado ao *bias* (Equação 1) (KANTARDZIC, 2011). O *bias*, valor ajustável, tem a função de reduzir ou aumentar a entrada líquida da função de ativação para o ajuste do v_j .

$$v_j = \sum_{i=1}^m w_{ji}x_i + b_j \quad (1)$$

sendo,

v_j : nível de atividade interna do neurônio;

w_{ji} : j -ésimo peso sináptico na iteração i ;


x_i : i -ésima entrada;

b_j : j -ésimo peso correspondente ao *bias*.

m : número total de entradas.

Ao se aplicar a função de ativação ao nível de atividade interna do neurônio obtém-se a saída y . Na Figura 2 são ilustradas duas das funções de ativação mais utilizadas: a tangente sigmoidal e a função linear. A função tangente sigmoidal em razão de sua não linearidade é geralmente aplicada nas camadas intermediárias e seu intervalo de trabalho é de -1 a 1, sendo necessária a normalização dos dados de entrada da função.

Figura 2. Representações gráficas das funções de ativação (A) tangente sigmoidal e (B) linear.



4.5.2 Lógica fuzzy

A manutenção do ambiente térmico dentro de intervalos de conforto para os frangos de corte é imperativa para que todo o potencial genético da linhagem seja explorado. Para tanto, o desenvolvimento de algoritmos (modelos matemáticos) de controle, que possam ser

embarcados em microcontroladores, torna-se necessário. Dentre os possíveis modelos a serem desenvolvidos, aqueles baseados em inteligência artificial, especificamente a metodologia *fuzzy* tem se mostrado mais adequada.

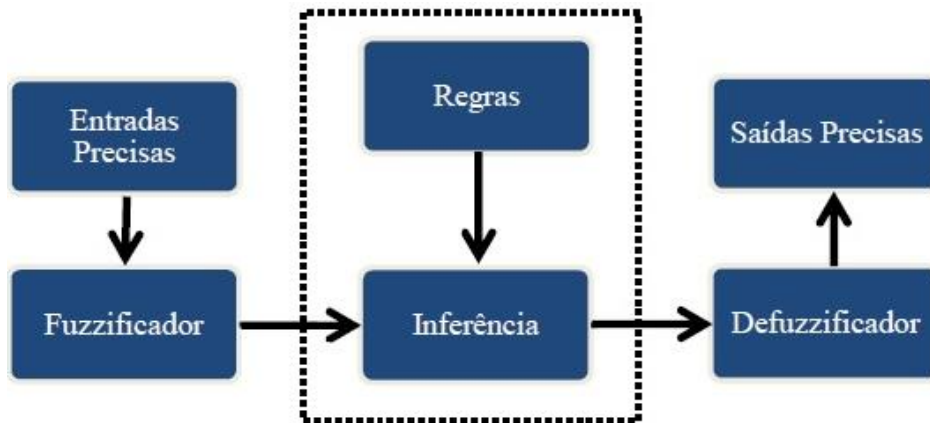
A teoria *fuzzy*, ou a teoria dos conjuntos nebulosos, foi apresentada por Zadeh (1965), a partir do qual se iniciaram as pesquisas para desenvolvimento da inteligência computacional, no qual se introduziu os graus de incerteza. Desta forma, um elemento pode pertencer parcialmente a um conjunto, modificando assim a teoria dos conjuntos clássicos que caracteriza elementos como pertencente ou não pertencente a um conjunto. Os elementos são determinados por uma função de pertinência, que está associada diretamente ao grau de estimativa do número, ou seja, ao grau de confiança sobre o número.

A lógica *fuzzy*, de acordo com Simões (1999), é considerada uma técnica que associa a natureza humana de pensar para controlar um sistema. Um modelador *fuzzy* particular pode ser elaborado para proceder-se análogo ao raciocínio dedutivo, ou seja, a maneira com que pessoas utilizam para afirmar suas decisões fundamentadas em informações já conhecidas.

Os conjuntos *fuzzy* e as funções de pertinência são determinados para cada variável de entrada e saída. Para o funcionamento do sistema ocorre a transformação dos valores reais de entrada em valores *fuzzy* que em seguida, é realizada a ativação e combinação de acordo com o conjunto fornecido para o sistema. O sistema de regras pode ser elaborado de acordo com dados numéricos e opiniões de especialistas. Após a combinação, os conjuntos *fuzzy* de saída se transformam em uma saída precisa do sistema.

De acordo com Mendel (1995), para a composição de uma modelagem *fuzzy*, o sistema pode ser programado ou utilizar um software que tenha o modelo matemático como ferramenta. O processo de construção do modelo se baseia nas etapas de fuzzificação (converte os valores de entrada em valores *fuzzy*), inferência (determina os valores de saída com base nos sistemas de regras pré-estabelecidos) e defuzzificação (converte os valores *fuzzy* em valores numéricos), de acordo com a Figura 3.

Figura 3 – Desenvolvimento computacional *fuzzy*.



Fonte: autor.

O sistema *fuzzy* é empregado em diversas áreas, tais como, em sistemas para controle de aeronaves e até mesmo em biomedicina (RIBACIONKA, 1999; ORTEGA, 2001; WEBER e KLEIN, 2003). A utilização da lógica *fuzzy* em construções e ambiência já tem demonstrado o seu potencial com pesquisas em conforto para aves (GATES et. al., 2001; AMENDOLA et al., 2005; YANAGI JUNIOR et al., 2006; FERREIRA et al., 2010; NASCIMENTO et al., 2011; FERREIRA et al., 2012), suínos (QUEIROZ et al., 2005), também para detectar a presença de cio em vacas leiteiras (FIRK et al., 2003, FERREIRA et al., 2006).

Uma vez que estudos demonstram uma boa eficiência na utilização da metodologia *fuzzy* quando aplicada para auxiliar na tomada de decisões, que se especificam pela presença de incerteza nas afirmações de “sim” e “não” (FERREIRA et al., 2010), pode-se dessa forma, utilizar o sistema *fuzzy* para prever o desempenho de frangos de cortes submetidos a diferentes intensidades e durações de estresse térmico durante as duas primeiras semanas de vida.

4.6 Controle do ambiente térmico de produção

Diversos problemas que ocorrem na produção intensiva de animais em ambientes fechados advêm da dificuldade de se manter o ambiente térmico dentro de certos limites considerados de conforto. Dentre as variáveis relacionadas ao ambiente térmico, as mais importantes são a temperatura, a umidade relativa e a velocidade do ar (SUKATI, 2004).

Os sistemas automatizados de climatização são capazes de controlar múltiplas variáveis em tempo real (LACY e CZARICK, 1994), entretanto a maioria é baseada, unicamente, na temperatura do ar (MITCHELL e HAMRITA, 1999).

Neste contexto, o desenvolvimento de algoritmos e ou sistemas de controle baseados em variáveis meteorológicas e respostas do próprio animal, possíveis de serem mensuradas automaticamente e de forma não invasiva pode propiciar melhorias nas condições de conforto dos animais, possibilitando o aumento do desempenho produtivo.

5 CONSIDERAÇÕES FINAIS

O ambiente térmico no interior de aviários influencia diretamente as respostas fisiológicas e produtivas dos frangos de corte, especialmente nas primeiras semanas de vida nas quais os pintinhos não possuem o sistema termorregulador completamente desenvolvido, apesar de serem homeotérmicos. Dessa forma, aquecimento se faz necessário.

O uso de inteligência artificial, como as redes neurais artificiais, pode propiciar um melhor controle do microclima de criação de pintinhos enquanto possibilita que um algoritmo seja embarcado em um sistema de aquisição e controle de temperatura.

6 REFERÊNCIAS BIBLIOGRÁFICAS

- ASSOCIAÇÃO BRASILEIRA DE PROTEÍNA ANIMAL - ABPA. **Relatório anual**. São Paulo, 2017.
- ABREU, P. G.; BAETA, F. C.; ABREU, V. M. N. Desempenho produtivo e bioeconômico de frangos de corte criados em diferentes sistemas de aquecimento. **Revista Brasileira de Zootecnia**, Viçosa, v. 29, n. 1, 2000.
- AMENDOLA, M.; NETO, M. M.; CRUZ, V.F. Using fuzzy sets theory to analyze environmental condition in order to improve animal productivity. **Biomatemática**, n.15, p. 29-40, 2005.
- AZADEH, A.; DARIVANDI SHOUSHARI; K., SABERI, M., & TEIMOURY, E. An Integrated Artificial Neural Network and System Dynamics Approach in Support of the Viable System Model to Enhance Industrial Intelligence: The Case of a Large Broiler Industry. **Systems Research and Behavioral Science**, v. 31, n. 2, p. 236-257, 2014.
- BARACHO, M. S.; CASSIANO, J. A.; NÄÄS, I. A.; TONON, G. S.; GARCIA, R. G.; ROYER, A. F. B.; SANTANA, M. R. Ambiente interno em galpões de frango de corte com cama nova e reutilizada. **Agrarian**, Dourados, v. 6, n. 22, p. 473-478, 2013.
- BORGES, S. A.; MAIORKA, A.; SILVA, A. V. F. D. Fisiologia do estresse calórico e a utilização de eletrólitos em frangos de corte. **Ciência Rural**, p. 975-981, 2003.
- CAMPOS, J.R.; LOTUFO, A. D.; MINUSSI, C. R.; LOPES, M.L. Implementação de redes neurais artificiais utilizando a linguagem de programação Java. **Proceedings of the 9th**

Brazilian Conference on Dynamics Control and their Applications. Serra Negra, SP, SBPO, p. 391-397, 2010.

CAMPOS, V.; SOUZA, F. O.; TORRES, L. A.; PALHARES, R. M. New stability conditions based on piecewise fuzzy Lyapunov functions and tensor product transformations. **IEEE Transactions on Fuzzy Systems**, v. 21, n. 4, p. 748-760, 2013.

CASSUCE, D. C. **Determinação das faixas de conforto térmico para frangos de corte de diferentes idades criados no Brasil.** 2011. 103 p. Tese (Doutorado em Engenharia Agrícola) - Universidade Federal de Viçosa, Viçosa, MG, 2011.

CLARK, J. A. **Environment aspects of housing for animal production.** Nothingam: University of Nothingam, 1981. 510 p.

COBB-VANTRESS. **Cobb500 Broiler Performance & Nutrition Supplement.** Siloam Springs, 2015. 14 p.

COLLATTO, D.C.; MANSILLA, R.B.; CHWIACOWSKY, L.D.; LACERDA, D. P. Avaliação de fontes de energia para o aquecimento de ambientes na produção de frango de corte no sul do Brasil: uma análise multicritério. **SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL**, Porto de Galinhas, 2015, 12p.

COSTA, E. J. X. Inteligência artificial aplicada à Zootecnia. **Revista Brasileira de Zootecnia**, v. 38, n. spe, p. 390-396, 2009.

CORDEIRO, M. B.; TINÔCO, I. D. F.; SILVA, J. N.; VIGODERIS, R. B.; PINTO, F. D. A. D. C.; CECON, P. R. Conforto térmico e desempenho de pintos de corte submetidos a diferentes sistemas de aquecimento no período de inverno. **Revista Brasileira de Zootecnia**, Viçosa, MG, v. 39, n. 1, p. 217-224, jan. 2010.

FERREIRA, L.; YANAGI JUNIOR, T.; NÄÄS, A. I.; LOPES, M.S. Predição de cio em vacas leiteiras utilizando lógica fuzzy. In: CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA, 35, 2006, João Pessoa. **Anais...** João Pessoa: SBEA, 2006.

FERREIRA, L.; YANAGI JUNIOR, T.; LOPES, A. Z.; LACERDA, W. S. Desenvolvimento de uma rede *neuro-fuzzy* para predição da temperatura retal de frangos de corte. **RITA**, Porto Alegre, v. 17, n. 2, p.221-233, 2010.

FERREIRA, L.; YANAGI JUNIOR, T.; LACERDA, W. S.; & RABELO, G. F.. A fuzzy system for cloacal temperature prediction of broiler chickens. **Ciência Rural**, Santa Maria, v. 42, n. 1, p. 166-171, jan. 2012.

FIORIN, DANIEL V.; FERNANDO R. MARTINS; NELSON J. SHUCH; ENIO B. PEREIRA. Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares. **Revista Brasileira de Ensino de Física** v. 33, n. 1, p.1309, 2011.

FIRK, R.; STAMER, E.; JUNGE, W.; KRIETER, J. Improving oestrus detection by combination of activity measurements with information about previous oestrus cases. **Livestock Production Science**, n. 82, p. 97-103, 2003.

FREEMAN, B. M. The fowl and its physical environment. **World's Poultry Science Journal**, Ithaca, v. 25, p. 99-111, 1968.

- FUNCK, S. R.; FONSECA, R. A. Avaliação energética e de desempenho de frangos com aquecimento automático a gás e a lenha. **Revista brasileira de engenharia agrícola e ambiental**, v.12, n. 1, p. 91-98, 2008.
- FURTADO, D. A.; ROCHA, H. P.; NASCIMENTO, J. W. B. do; SILVA, J. H. V. Índices de conforto térmico e concentração de gases em galpões avícolas no semiárido paraibano. **Engenharia Agrícola**, v.30, p.993-1002, 2010.
- GATES, R. S.; CHAO, K.; SIGRIMIS, N. Identifying design parameters for fuzzy control of staged ventilation control systems. **Computers and Eletronics in Agriculture**, v.31, p.61-74, 2001.
- KANTARDZIC, M. Data mining: concepts, models, methods, and algorithms (2011). New Jersey: John Wiley & Sons, 2nd edition, p.53
- LACY, M. P.; CZARICK, M. (1994). Field testing of a mechanized broiler harvesting system. **Poult. Sci**, v.73, n. Suppl 1, 41.
- MAY, J. D.; LOTT, B. D. The effect of environmental temperature on growth and feed conversion of broilers to 21 days of age. **Poultry Science**, Champaign, v. 79, n. 5, p. 669-671, May 2000.
- 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.
- MENDEL, J. M. **Fuzzy logic systems for engineering**: A tutorial. IEEE, v. 83, n. 03, p. 345-377, 1995.
- MENEGALI, I.; BAETA, F. C.; TINÔCO, I. F. F.; CORDEIRO, M. B.; GUIMARÃES, M. C. C. Desempenho produtivo de frangos de corte em diferentes sistemas de instalações semiclimatizadas no sul do Brasil. **Engenharia na Agricultura**, Viçosa, MG, v. 18, n. 6, p. 461-471, nov./dez. 2010.
- MENEGALI, I.; TINOCO, I. F. F.; CARVALHO, C. C. S.; SOUZA, C. D. F.; MARTINS, J. H. Comportamento de variáveis climáticas em sistemas de ventilação mínima para produção de pintos de corte. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 17, n. 1, jan. 2013.
- MILLINGTON, I. Artificial Intelligence for Games. San Francisco, California, **Morgan Kaufmann Publishers Inc.**, 2006, 856p.
- MITCHELL, B.; HAMRITA, T. K. Poultry Environment and production control and optimization: A summary of where we are and where we want to go. **Transaction of the ASAE**, Saint Joseph, v. 42, n. 2, p. 479-483. 1999.
- MOURA, D. J.; NÄÄS, I. A.; PEREIRA, D. F.; SILVA, R. B. T. R.; CAMARGO, G. A. Animal welfare concepts and strategy for poultry production: a review. **Revista Brasileira de Ciência Avícola**, Campinas, v. 8, n. 3, p. 137-148, jul./set. 2006.
- NASCIMENTO, G. R. D.; PEREIRA, D. F.; NÄÄS, I. D. A.; RODRIGUES, L. H. Índice *fuzzy* de conforto térmico para frangos de corte. **Engenharia Agrícola**, Jaboticabal, v. 31, n. 2, p. 219-229, mar./abr. 2011.

NAZARENO, A. C.; PANDORFI, H.; ALMEIDA, G. L.; GIONGO, P. R., PEDROSA, E. M.; & GUISELINI, C. Avaliação do conforto térmico e desempenho de frangos de corte sob regime de criação diferenciado. **Revista Brasileira de Engenharia Agrícola Ambiental**, Campina Grande, v. 13, n. 6, p. 802-808, nov./dez. 2009.

OLESKOVICZ, M.; COURY, D. V.; AGGARWAL, R. K. O emprego de redes neurais artificiais na detecção, classificação e localização de faltas em linhas de transmissão. **Sba Controle & Automação [online]**, v.14, n.2, p.138-150, 2003.

OLIVEIRA, R. F. M.; DONZELE, J. L.; ABREU, M. L. T.; FERREIRA, R. A.; VAZ, R. G. M. V.; CELLA, P. S. Efeitos da temperatura e da umidade relativa sobre o desempenho e o rendimento de cortes nobres de frangos de corte de 1 a 49 dias de idade. **Revista Brasileira de Zootecnia**, Viçosa, MG, v. 35, n. 3, p. 797-803, 2006.

OLIVEIRA NETO, H. M. D. C. Níveis de Energia Metabolizável para Frangos de Corte de 1 a 21 Dias de Idade Mantidos em Ambiente de Alta Temperatura¹. **Revista Brasileira de Zootecnia**, v. 29, n. 3, p. 810-816, 2000.

ORTEGA, N. R. S. **Aplicação da teoria de conjuntos fuzzy a problemas da biomedicina**. São Paulo: USP, 2001. 152p. (Tese de doutorado).

PONCIANO, P. F.; YANAGI JUNIOR, T.; SCHIASSI, L.; CAMPOS, A. T.; NASCIMENTO, J. W. B. Sistema fuzzy para predição do desempenho produtivo de frangos de corte de 1 a 21 dias de idade. **Engenharia Agrícola**, Jaboticabal, v. 32, n. 3, p.446-458, maio./jun. 2012.

QUEIROZ, M.; NÄÄS, I. A.; SAMPAIO, C. **Estimating thermal comfort of piglets considering ammonia concentration**. Agricultural Engineering International: the CIGR Ejournal, Manuscript IT 05 004/BC 05 005, v. 03, 2005.

RIBACIONKA, F. **Sistemas computacionais baseados em lógica fuzzy**. São Paulo: Universidade Mackenzie, 1999. 115p. (Tese de mestrado).

SALGADO, D. D.; NÄÄS, I. D. A.; PEREIRA, D. F.; MOURA, D. J. D. Modelos estatísticos indicadores de comportamentos associados a bem-estar térmico para matrizes pesadas. **Revista Engenharia Agrícola**, Jaboticabal, v. 27, n. 3, p. 619-629, dez. 2007.

SELLITTO, M. A. Inteligência Artificial: Uma Aplicação em uma Indústria de Processo Contínuo. **Gestão & Produção**, v.9, n.3, p.363-376, dez. 2002.

SILVA, M.A.N.D.; HELLMEISTER FILHO, P.; ROSÁRIO, M. F.; COELHO, A. A. D.; SAVINO, V. J. M.; GARCIA, A. A. F.; SILVA, I. J. O.; MENTEN, J. F. M. Influência do sistema de criação sobre o desempenho, a condição fisiológica e o comportamento de linhagens de frangos para corte. **Revista Brasileira de Zootecnia**, v. 32, n. 1, p.208-213, 2003.

SILVA, R. M.; ALMEIDA, T. A.; YAMAKAMI, A. Análise de desempenho de redes neurais artificiais para classificação automática de web spam. **Revista Brasileira de Computação Aplicada**, v. 4, n.2 ,p. 42-57, 2012

SIMÕES, M. G. **Controle e modelagem fuzzy**. São Paulo: E. Blücher, 1999. 165 p.

SUKATI, N. E. **Environmental Control Systems in Poultry houses**. 2004. 27 p. Monografia (Graduação em Engenharia Agrícola) – University of KwaZulu, Pietermaritzburg.

TEIXEIRA, E. N. M.; SILVA, J. H. V.; COSTA, F. G. P.; MARTINS, T. D. D.; GIVISIEZ, P. E. N.; FURTADO, D. A. Efeito do tempo de jejum pós-eclosão, valores energéticos e inclusão do ovo desidratado em dietas pré-iniciais e iniciais de pintos de corte. **Revista Brasileira de Zootecnia**, Viçosa, MG, v. 38, n. 2, p. 314-322, fev. 2009.

TINÔCO, I. F. F. Avicultura industrial: novos conceitos de materiais, concepções e técnicas construtivas disponíveis para galpões avícolas brasileiros. **Revista Brasileira de Ciência Avícola**, Campinas, v. 3, n. 1, p. 1-26, 2001.

TINÔCO, I. F. F.; FIGUEIREDO, J. L. A.; SANTOS, R. C. Placas porosas utilizadas em sistemas de resfriamento evaporativo. **Revista Engenharia na Agricultura**, Viçosa, MG, v. 12, n. 1, p. 17-23, 2004.

VIGODERIS, R. B.; CORDEIRO, M. B.; TINÔCO, I. F. F.; MENEGALI, I.; SOUZA JÚNIOR, J. D.; HOLANDA, M. D. Avaliação do uso de ventilação mínima em galpões avícolas e de sua influência no desempenho de aves de corte no período de inverno. **Revista Brasileira de Zootecnia**, v. 39, n. 6, p. 1381-1386, 2010.

WEBER, L.; KLEIN, P. A. T. **Aplicações de lógica fuzzy em software e hardware**. Canoas: Editora ULBRA, 2003. 112p

YANAGI JUNIOR, T.; XIN, H.; GATES, R.S.; FERREIRA, L. Fuzzy logic model to predict laying hen body temperature rise during acute heat stress. In: CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA, 35, 2006, João Pessoa. **Anais...** João Pessoa: SBEA, 2006.

YOUSEF, M. K. **Stress physiology in Livestock**. Las Vegas: CRC, 1985. 159 p. (Basic Principle, 3).

ZADEH, L. A. Fuzzy sets. **Information and control**, v. 8, n. 3, p. 338-353, 1965.

SEGUNDA PARTE – ARTIGO**ARTIGO 1****Redes neurais artificiais aplicadas à predição da temperatura superficial de frangos de corte jovens****Artificial neural networks applied to broiler chicks surface temperature prediction**

Artigo redigido conforme norma da Revista Científica “*Computers in Biology and Medicine*”.

Resumo: A temperatura superficial (T_s) de frangos de corte é afetada pelas condições térmicas circundantes à ave, podendo, desta forma, ser usada para predizer o *status* de conforto destes animais e para o controle de sistemas de aquecimento. Objetivou-se com o presente trabalho, desenvolver uma rede neural artificial (RNA) para predição da T_s de frangos de corte. Dados de T_s das aves foram mensurados por meio de termografia infravermelha após os animais serem submetidos a desafios térmicos em diferentes intensidades na primeira (temperatura do ar, T_{ar} : 27, 30, 33 e 36°C) e segunda (T_{ar} : 24, 27, 30 e 33°C) semanas de vida das aves e durações (1, 2, 3 e 4 dias). A umidade relativa e a velocidade do ar foram mantidas em 60% e 0,2 m s⁻¹, respectivamente. O banco de dados, com 630 registros, foi aleatoriamente dividido para o treinamento (70%), teste (15%) e validação (15%) de 100 RNAs, sendo que, escolheu-se a de melhor desempenho. Para o desenvolvimento das RNAs as variáveis de entrada foram a idade das aves (I) e a T_{ar} , e a variável de saída a T_s . As RNAs desenvolvidas adotaram a arquitetura *multilayer-perceptron* (MLP) com uma camada de entrada, uma camada escondida (oculta ou intermediária) e uma de saída. Os desempenhos das RNAs foram quantificados por meio do erro absoluto médio (MAE), erro percentual absoluto médio (MAPE), erro quadrático médio (MSE), raiz quadrada do erro quadrático médio (RMSE) e coeficiente de determinação (R^2). A RNA com com 10 neurônios na camada escondida e fornecida pelo sexto treinamento obteve o melhor desempenho, com valores de MAE, MAPE, MSE, RSME e R^2 de validação de 0,4666, 1,3946, 0,3229, 05683 e 0,9118, respectivamente. A RNA-MLP desenvolvida apresenta desempenho adequado, podendo ser usada na predição da T_s e podendo ser embarcada em controladores de sistemas de aquecimento de aviários para criação de frangos de corte.

Palavras-Chave: Inteligência artificial, RNA, avicultura de corte, termografia

I. INTRODUÇÃO

O conforto térmico pode ser quantificado pelas respostas fisiológicas do animal em relação ao ambiente térmico que o circunda. Condições de estresse térmico influenciam de forma negativa as respostas fisiológicas, produtivas e comportamentais de frangos de corte. Dentre as diversas respostas fisiológicas, a temperatura superficial de frangos de corte tem se destacado devido o método de medição ser não invasivo.

A temperatura superficial tem sido avaliada por meio da termografia infravermelha em diversas pesquisas aplicadas a frangos de corte (Tao e Xin, 2003), galinhas poedeiras (Yanagi Junior et. al., 2003), equinos (Moura et al., 2011), dentre outras.

A inteligência artificial, metodologia computacional capaz de simular o modo de pensar humano, tem sido usada para prever as respostas fisiológicas (Schiassi et al, 2008; Ferreira et al., 2010; Ferreira et al., 2012; Lopes et al., 2014; Hernández-Julio et al., 2014; Julio et al., 2015), produtivas (Ponciano et al., 2012; Ponciano et al., 2014; Abreu et al., 2015), reprodutivas (Yanagi Junior et al., 2007) e comportamentais (Campos et. al., 2013). Dentre os modelos baseados em inteligência artificial, as redes neurais artificiais (RNAs) têm obtido destaque, uma vez que tais redes podem ser aplicadas em tempo real, têm poder de autoadaptação, são capazes de resolver problemas práticos e não têm a dependência a listas de regras ou modelos precisos (Pandorfi et al., 2011).

Neste contexto, objetivou-se com o presente estudo, desenvolver, testar e validar uma RNA capaz de prever a temperatura superficial de frangos de corte com idades variando de 1 a 14 dias.

II. MATERIAL E MÉTODOS

A. Experimentação e bancos de dados

Os dados experimentais usados para o desenvolvimento das redes neurais artificiais (RNAs) foram obtidos de dois experimentos conduzidos em quatro túneis de vento climatizados, nos quais frangos de corte da linhagem Cobb500[®] foram submetidos a desafios térmicos compostos por quatro valores de temperatura do ar (Tar) na primeira (27, 30, 33 e 36 °C) e segunda (24, 27, 30 e 33°C) semanas de vida.

Detalhes sobre os túneis de vento climatizados e sistemas de aquisição e controle podem ser obtidos em Schiassi et al. (2014) e sobre os dois experimentos a partir do qual foram gerados os dados usados nesta pesquisa podem ser obtidos em Abreu (2015) e Ferraz et al. (2017).

Os desafios térmicos foram compostos pelas Tar preconizadas como de conforto para frangos de corte nas respectivas faixas etárias, que é de 33 °C na primeira semana e 30 °C na segunda semana (Cony e Zocche, 2004; Menegali et al., 2013), e valores que caracterizavam desconforto térmico por baixa e alta temperaturas. A umidade relativa (UR) e velocidade do ar (V) foram mantidas em $60 \pm 0,75\%$ e $0,2 \pm 0,05 \text{ m s}^{-1}$, considerados como de conforto térmico para frangos de corte (Medeiros et al., 2005). Ambos experimentos foram aprovados pela Comissão de Ética no Uso de Animais (CEUA) da Universidade Federal de Lavras (Protocolos n° 001/12 e 008/12, respectivamente).

Os túneis de vento climatizados possuíam controle automático da Tar ($\pm 0,19 \text{ °C}$) e umidade relativa do ar (UR) ($\pm 0,75\%$), e controle manual da velocidade do ar ($\pm 0,05 \text{ m s}^{-1}$). Tar e UR foram medidas por meio de sensores de temperatura e umidade (HMP45C,

Vaisala, com acurácia de $\pm 0,3$ °C e $\pm 2\%$, respectivamente) acoplados a um datalogger controlador (Campbell Scientific, modelo CR1000). A temperatura superficial dos frangos de corte (T_s) foi mensurada por meio de uma câmera termográfica (Fluke, modelo TI55FT20/54/7.5, acurácia de $\pm 0,05$ °C).

Um banco de dados, contendo 630 registros compostos por idade de frangos de corte (I), Tar e T_s oriundos destes dois experimentos foram usados para o desenvolvimento de RNAs. Os intervalos dos valores de I, Tar e T_s observados foram de 1 a 14 dias, 24 a 36 °C e 25,70 a 37,92 °C, respectivamente.

Posteriormente, o banco de dados inicial, com 630 registros, foi subdividido randomicamente em três bancos de dados, sendo que, 70% (440 registros) foram usados no treinamento, 15% (95 registros) no teste e 15% (95 registros) na validação das RNAs (Hernández-Julio et al., 2014).

B. Desenvolvimento da rede neural artificial

Para o desenvolvimento das RNAs as variáveis de entrada foram I e Tar, e a variável de saída a T_s . As RNAs desenvolvidas adotaram a arquitetura *multilayer-perceptron* (MLP) com uma camada de entrada, uma camada escondida (oculta ou intermediária) e uma de saída.

Para facilitar a convergência da variável de saída na etapa de treinamento da rede, bem como, para possibilitar o uso da função tangente sigmoideal de ativação da camada escondida, todos os dados foram normalizados entre -1 e 1 (Equação 1).

$$y_n = \frac{(y_{max,n} - y_{min,n}) \cdot (x - x_{min})}{(x_{max} - x_{min})} + y_{min,n} \quad (1)$$

em que,

y_n : é o valor normalizado da variável de entrada (entre -1 e 1);

$y_{min,n}$ e $y_{max,n}$: são os limites mínimo e máximo desejados para a normalização, recebendo os valores de -1 e 1, respectivamente;

x : é o valor da variável de entrada a ser normalizada e;

x_{min} e x_{max} : são os valores mínimo e máximo da variável de entrada a ser normalizada.

A saída não linear de cada neurônio (Equação 2) é obtida pela aplicação da função de ativação ao nível de ativação interna do neurônio (Kantardzic, 2011). A função de ativação tangente sigmoideal (Equação 3) foi usada na camada escondida da RNA-MLP por serem contínuas, crescentes, diferenciáveis e não-lineares (Fiorin et al., 2011).

$$y_j = \varphi(v_j) \quad (2)$$

$$\varphi(v_j) = \frac{2}{(1+\exp(-2 \cdot v_j))} - 1 \quad (3)$$

sendo,

y_i : saída do j -ésimo neurônio;

$\varphi(v_j)$: função de ativação não linear aplicada à camada escondida.

A função de ativação linear ($\alpha = 1$) (Equação 4) foi usada na camada de saída, que considera que a saída seja igual ao nível de atividade interna, conforme recomendado por diversos autores (Fiorin et al., 2011; Klassen et al., 2009).

$$\varphi(V_j) = \alpha \cdot V_j; \quad (4)$$

em que,

$\varphi(V_j)$: função de ativação linear aplicada à camada de saída;

α : coeficiente angular;

V_j : soma ponderada dos sinais que produz um nível de atividade.

A desnormalização da variável de saída foi calculada pela expressão 5.

$$x_d = \frac{(y_n - y_{\min,n}) \cdot (x_{\max} - x_{\min})}{(y_{\max,n} - y_{\min,n})} + x_{\min} \quad (5)$$

em que,

x_d : é o valor desnormalizado da variável saída;

$y_{\min,n}$ e $y_{\max,n}$: são os limites mínimo e máximo desejados para a normalização, recebendo os valores de -1 e 1, respectivamente;

y_n : é o valor da variável de saída a ser desnormalizada e;

x_{\min} e x_{\max} : são os valores mínimo e máximo da variável de saída a ser desnormalizada.

Neste trabalho foram testadas 10 topologias diferentes, cujos neurônios da camada escondida variaram de 1 a 10, sendo testadas 10 vezes cada, totalizando 100 redes. A capacidade de generalização de uma rede aumenta com o aumento do número de treinamentos, fornecendo resultados diferentes devido as condições iniciais e amostragens usadas serem diferentes (Fiorin et al., 2011). Contudo, se o número de treinamentos for muito elevado, pode ocorrer *overtraining* (Sjöberg e Ljung, 1992).

C. Treinamento, teste e validação das RNAs

Os três bancos de dados subdivididos randomicamente em 70% (440 registros), 15% (95 registros) e 15% (95 registros) foram usados para o treinamento, teste e validação das RNAs (Hernández-Julio et al., 2014). Na fase de treinamento, os 70% dos dados experimentais foram apresentados à RNA, que é ajustada e se obtém o erro de treinamento. Para o treinamento não existe um número pré-definido de dados (registros) necessários, entretanto, esta quantidade deve ser suficiente para o aprendizado da rede (Klassen et al., 2009). Os dados de teste não afetam o treinamento e fornecem uma medida independente da performance da rede durante e após o treinamento (Oliveira et al., 2010). Os dados de validação são usados para quantificar a capacidade de generalização da rede e para finalizar o treinamento quando se encerram as melhorias referentes à generalização.

Os parâmetros usados no treinamento das RNAs foram: número máximo de épocas: 1000, desempenho minimizado até a meta: 0, gradiente de desempenho mínimo: e^{-7} e ajuste de Marquardt (μ): 0,001. A rede foi treinada com o algoritmo Levenberg-Marquardt (Levenberg, 1944; Marquardt, 1963), por ser mais rápido para redes de tamanho moderado (Fiorin et al., 2011).

Os desempenhos das RNAs foram quantificados por meio do erro absoluto médio (MAE) (Equação 6), erro percentual absoluto médio (MAPE) (Equação 7), Erro

quadrático médio (MSE) (Equação 8), raiz quadrada do erro quadrático médio (RMSE) (Equação 9) e coeficiente de determinação (R^2) (Equação 10).

$$MAE = \frac{1}{n} \sum_{i=1}^n |T_{S_{obs,i}} - T_{S_{pred,i}}| \quad (6)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{T_{S_{obs,i}} - T_{S_{pred,i}}}{T_{S_{obs,i}}} \right| \cdot 100 \quad (7)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (T_{S_{pred,i}} - T_{S_{obs,i}})^2 \quad (8)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (T_{S_{pred,i}} - T_{S_{obs,i}})^2} \quad (9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (T_{S_{pred,i}} - T_{S_{obs,i}})^2}{\sum_{i=1}^n (T_{S_{pred,i}} - \bar{x})^2} \quad (10)$$

Sendo que,

$T_{S_{pred,i}}$ = i -ésima temperatura superficial predita ($^{\circ}\text{C}$);

$T_{S_{obs,i}}$ = i -ésima temperatura superficial observada ($^{\circ}\text{C}$);

n = número total de amostras;

\bar{x} = temperatura superficial média observada ($^{\circ}\text{C}$).

III. RESULTADOS E DISCUSSÃO

Para a predição da T_s , RNAs com 10 topologias diferentes e testadas de 1 a 10 vezes foram treinadas, totalizando 100 redes. Em seguida, as médias e os desvios padrões de cada conjunto de redes com topologia similar (mesmo número de neurônios na camada

escondida) foram calculadas (Tabela 1) para se obter a melhor topologia da RNA. Desta forma, a topologia com 10 neurônios na camada escondida apresentou o menor MSE de treinamento (0,4471) e maior R^2 de validação (0,8704), sendo então, a escolhida para a predição de Ts (Tabela 1).

Tabela 1. Erros médios de predição da temperatura superficial de frangos de corte, com idades variando de 1 a 14 dias e submetidos a diferentes desafios térmicos, para diversas topologias de RNA.

Topologia*	MSE		Coeficiente de determinação (R^2)					
	(Treinamento)		Treinamento		Teste		Validação	
	Média	DP	Média	DP	Média	DP	Média	DP
1	1,3276	0,205	0,6603	0,0137	0,6728	0,0528	0,6330	0,0593
2	0,9083	0,2317	0,7277	0,0642	0,7233	0,0728	0,7441	0,0615
3	0,6745	0,2172	0,8303	0,0221	0,8143	0,0460	0,8042	0,0598
4	0,5337	0,0534	0,8436	0,0077	0,8421	0,0248	0,8490	0,0285
5	0,6016	0,1462	0,8555	0,0152	0,8355	0,0410	0,8294	0,0345
6	0,5556	0,1481	0,8516	0,0125	0,8572	0,0352	0,8336	0,0309
7	0,4624	0,0505	0,8549	0,0090	0,8495	0,0297	0,8691	0,0265
8	0,5872	0,2211	0,8615	0,0144	0,8529	0,0322	0,8411	0,0383
9	0,4917	0,0474	0,8527	0,0138	0,8474	0,0290	0,8645	0,0230
10	0,4471	0,0748	0,8554	0,0137	0,8547	0,0418	0,8704	0,0223

* Número de neurônios na camada escondida.

Dentre as 10 RNAs treinadas para a melhor topologia (10 neurônios na camada escondida), aquela obtida no sexto treinamento foi a que apresentou melhor R^2 de validação ($R^2 = 0,9118$) (Tabela 2). Os valores dos R^2 das RNAs ajustadas variaram de

0,8419 a 0,9118. Na Tabela 2 também são listados os valores de MAE, MAPE, MSE, RMSE e R^2 da rede com melhor desempenho para as fases de treinamento, teste, validação e todos os dados (treinamento, teste e validação).

Tabela 2. Erros de predição da temperatura superficial de frangos de corte, com idades variando de 1 a 14 dias e submetidos a desafios térmicos, para a RNA que obteve o melhor desempenho (Topologia 10).

Índices estatísticos	Treinamento	Teste	Validação	Todos os dados
Erro absoluto médio (MAE)	0,5375	0,5298	0,4666	0,5256
Erro percentual absoluto médio (MAPE)	1,5993	1,6184	1,3946	1,5713
Erro quadrático médio (MSE)	0,4741	0,7452	0,3229	0,4922
Raiz quadrada do erro quadrático médio (RMSE)	0,6885	0,8632	0,5683	0,7015
Coefficiente de determinação (R^2)	0,8659	0,7804	0,9118	0,8601

Valores de R^2 e MSE de 0,93 e 7,43 foram observados na fase de treinamento e de 0,91 e 6,84 na fase de teste em uma RNA desenvolvida para predição do ganho de peso médio diário (GPD) em função do nível de threonina como aminoácido na alimentação de frangos de corte (Ahmadi e Golian, 2010). Mottaghitalab et al. (2010) ao avaliarem o desempenho de RNAs para estimativa da eficiência calórica e de alimentação em perus machos observaram respectivos valores de R^2 , MAPE e MSE nas fases de treinamento (0,999, 0,025 e $3,04 \times 10^{-5}$) e teste (0,9993, 0,023 e $2,24 \times 10^{-5}$).

Karadurmus et al. (2012) investigaram por meio de uma RNA, um modelo de predição dos efeitos de dejetos de frangos em lençóis freáticos. Nas fases de treinamento e teste, a rede apresentou R^2 e MAPE de 0,96 e 0,072 e de 0,95 e 0,387, respectivamente.

Demirel et al. (2012) treinaram três RNAs para prever a temperatura do cérebro de ratos em função das temperaturas do reto, da orelha esquerda e da orelha direita. As

RNAs apresentaram valores de MSE de 0,0010, 0,0027 e 0,0040, respectivamente. O RMSE da RNA com melhor desempenho (temperatura do cérebro em função da temperatura retal) foi de 0,032 °C.

Faridi et al. (2013) desenvolveram quatro RNAs para estimar o peso de ovos em matrizes de corte na 25^a, 26^a, 27^a e 28^a semanas de vida, respectivamente, em função da energia metabolizável, proteína crua, amino ácidos, Ca e fósforo disponível. Os quatro modelos apresentaram os seguintes intervalos de valores de R^2 e MSE nas fases de treinamento (0,83 a 0,98 e 0,025 a 0,40 ovos², respectivamente) e de teste (0,83 a 0,97 e 0,029 a 0,39 ovos², respectivamente).

Faridi et al. (2016) ajustaram uma RNA para predição do ganho de peso médio diário (GPD), consumo de ração (CR) e conversão alimentar (CA) de frangos de corte, com idades variando de 1 a 14 dias, em função dos níveis de aminoácido sulfúrico total e proteína. Os valores de R^2 e MSE variaram de 0,95 e 2,30, 0,82 e 4,8 e 0,99 e 0,0, respectivamente.

Gitoe et al. (2017) ajustaram diversos modelos (regressão e RNA) para predição do GPD de frangos de corte em resposta aos níveis de proteína na dieta e de aminoácidos. Os modelos de regressão testados foram o linear, o polinomial de 2^a e 3^a ordem, a função de base radial e a sigmoideal. As RNAs ajustadas foram a MLP e a função de base radial. Para os modelos de regressão para estimativa do GPD na fase de treinamento, os valores de 0,71 a 0,77, 2,15 a 2,65 e 9,10 a 11,14 foram observados para R^2 , MAE e MSE, respectivamente. Para a fase de teste, estes valores foram de 0,69 a 0,77, 2,17 a 2,62 e 8,50 a 11,70, respectivamente. Por sua vez, os valores de 0,75 e 0,81, 1,83 e 2,29 e, 6,70 e 8,81 foram observados, respectivamente, para as RNAs de base radial e a sigmoideal na

fase de treinamento. Na fase de teste os valores foram de 0,75 e 0,81, 1,88 e 2,25 e 6,86 e 8,70, respectivamente.

Nazareno et al. (2016) desenvolveram uma rede neural para prever a temperatura superficial média de pintainhos de corte e microclima da carga durante o transporte. Dentre as variáveis de entrada tem-se temperatura do ar, umidade relativa e temperatura superficial média durante carga. Uma regressão linear também foi ajustada com R^2 de 0,910.

Ferreira et al. (2010) desenvolveram e validaram uma rede neuro-*fuzzy* com o objetivo de prever a temperatura cloacal de frangos de corte. As variáveis de entrada foram temperatura do ar, umidade relativa e velocidade do ar. A rede neuro-*fuzzy* apresentou coeficientes de determinação (R^2) para treinamento e validação de 0,91 e 0,85, respectivamente.

Michael et al. (2017) desenvolveram redes neurais para criar modelos preditivos de temperatura corporal e temperatura da pele local em seres humanos. Dentre as partes do corpo avaliadas destacam-se as mãos que apresentaram um coeficiente de correlação de 0,931 e coeficiente de determinação R^2 de 0,867. Ferraz et al. (2014) desenvolveram RNAs e redes neuro-*fuzzy* para prever a massa corporal de pintinhos submetidos a várias durações e intensidades de desafios térmicos. Para os modelos testados (RNA e Neuro-*fuzzy*) foram apresentados como índices estatísticos o erro percentual médio, R^2 e RMSE. Para a RNA os erros foram 1,2, 0,9993 e 1,63, respectivamente. Para a rede Neuro-*fuzzy* os erros foram 2,1, 0,9970 e 2,65, respectivamente.

A Figura 1 ilustra a relação funcional entre os valores de T_s observados e preditos pela RNA de melhor desempenho para as fases de treinamento, teste, validação e usando todo o conjunto de dados. Os valores de R^2 obtidos estão nos intervalos encontrados por

Faridi et al. (2013) e Faridi et al. (2016). Outros autores encontraram valores inferiores (Gitoee et al., 2017) e superiores (Ahmadi e Golian, 2010; Mottaghitlab et al., 2010) à rede ajustada. Os valores de R^2 calculados estão próximos ao obtido (0,9389) por Pandorfi et al. (2011), corroborando com os autores quanto a possibilidade de aplicação da RNA ajustada para predição da Ts. Desta forma, a RNA ajustada pode auxiliar no suporte a tomada de decisão em aviários quanto ao acionamento de sistemas de aquecimento.

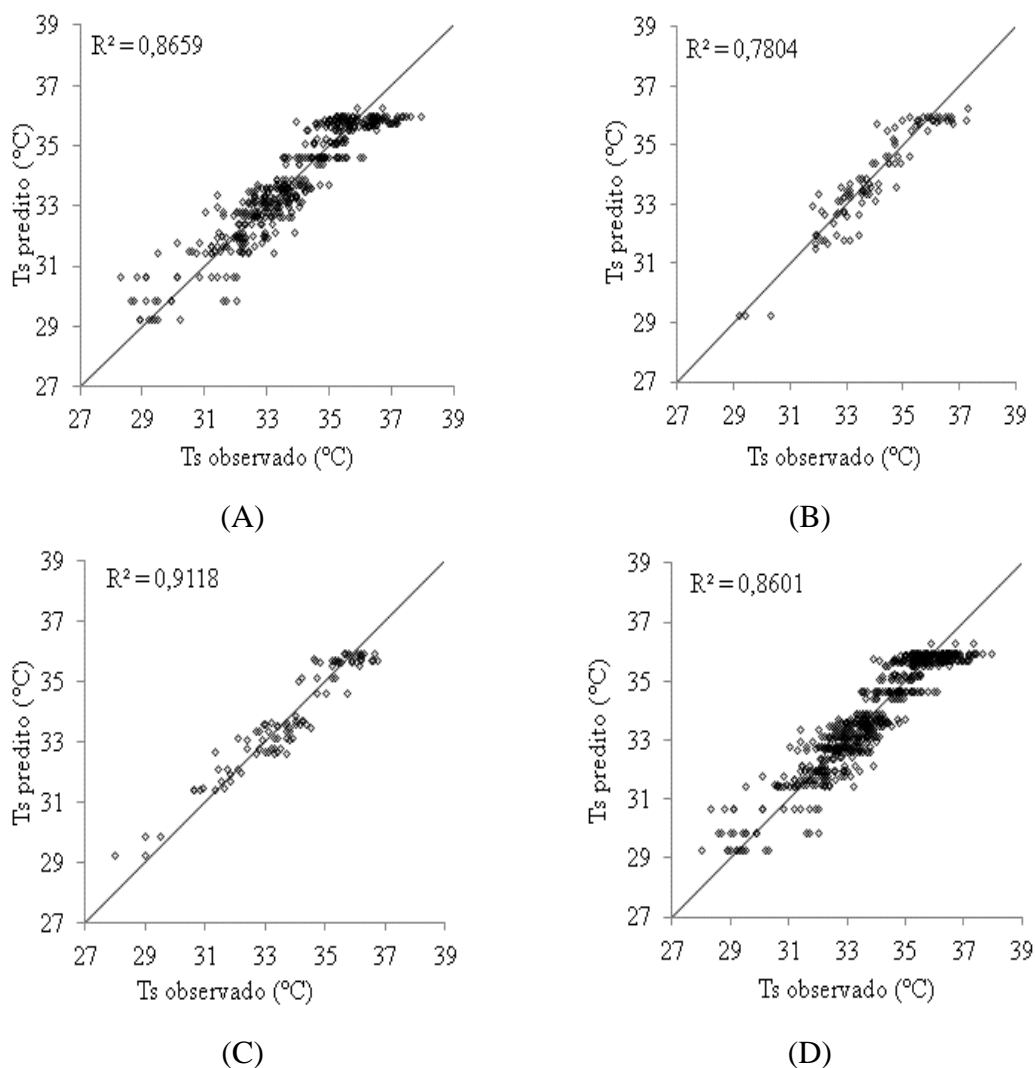


Figura 1. Relações funcionais entre as temperaturas superficiais de frangos de corte preditas e observadas para os conjuntos de dados usados no desenvolvimento da RNA que obteve o melhor desempenho, A) treinamento, B) teste, C) validação e D) todos os dados.

O detalhamento da distribuição dos desvios absolutos de predição da Ts obtidos pela RNA de melhor desempenho é ilustrado na Figura 2. Verifica-se que os erros se concentraram nas classes iniciais, ressaltando a capacidade de predição da rede. A aplicação desta análise corrobora com a de diversos autores (Kawakami e Vazzoler, 1980; Ferreira e Casatti, 2006; Turi et al., 2012, Ferraz et al., 2014).

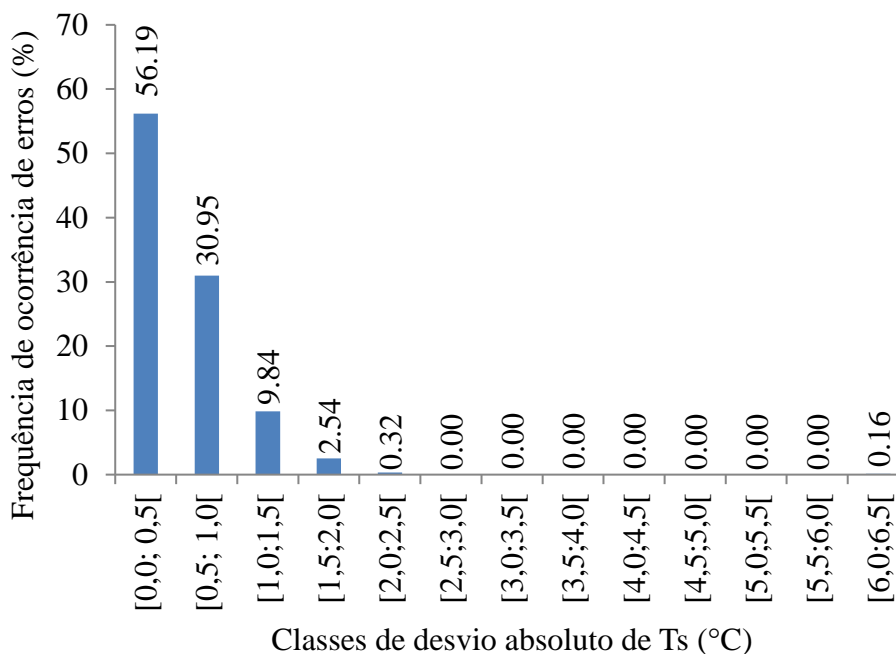


Figura 2. Frequência de ocorrência de erros de predição da temperatura superficial de frangos de corte (Ts).

As Tabelas 3 e 4 listam os valores dos pesos e *bias* de todos os 10 neurônios da camada escondida além dos pesos e *bias* que devem ser aplicados ao neurônio de saída.

Estes dados, oriundos da fase de treinamento, são necessários para o desenvolvimento de um *software* que represente a melhor RNA desenvolvida, possibilitando a realização de simulações ou o embarque em controlador para o manejo do ambiente térmico. Este *software* pode ser facilmente implementando em qualquer

linguagem de programação com poucas linhas de comando, diferentemente do processo de desenvolvimento da RNA, que é mais complexo e demanda maior tempo.

Tabela 3. Pesos das variáveis de entrada idade (I) e temperatura do ar (Tar) dos neurônios da camada escondida ($W_{CE,I}$ e $W_{CE,Tar}$, respectivamente) e *bias* resultantes do processo de treinamento da RNA que obteve melhor desempenho.

Número do neurônios	Bias_{CE}	$W_{CE,I}$	$W_{CE,Tar}$
1	-4,2494814716985300	3,022265884419170	-1,728805528953590
2	-4,0886752730400700	0,342305427724210	3,327562096233540
3	-3,0730894116065500	4,172068317207590	-0,978870644528134
4	-1,6960263597305400	1,389144846711940	-4,317676765264910
5	0,8356704836155040	7,331552746961300	0,360510275494199
6	-0,2372703108018310	4,185557209978070	1,810922649818450
7	0,2753694582983240	-0,543357034215556	3,748931802587860
8	-0,0934815054552587	1,479198799560480	-5,635903381643780
9	-3,6781213018859600	-4,090949437892470	7,837998463602350
10	2,9061197088476800	3,230165285177230	1,995350407581710

Tabela 4. Pesos da variável de saída temperatura superficial do frango de corte do neurônio da camada de saída ($W_{CS,Ts}$) e *bias* resultante do processo de treinamento da RNA que obteve melhor desempenho.

Número da Entrada	Bias _{CS}	$W_{CS,Ts}$
1		-0,106813969905784000
2		0,134407008515402000
3		0,254435475156953000
4		-0,901980885846041000
5	0,0871641053913887	0,092058872795779300
6		0,073030214739272800
7		-1,692855527727450000
8		-0,960103313860364000
9		0,402413848963285000
10		0,402991550051830000

O fluxograma do algoritmo para predição da T_s em função de I e T_{ar} para a arquitetura de melhor desempenho é ilustrado na Figura 3. Esta forma de generalização de uso do modelo, adotada por alguns autores (Bacurau et al., 2011; Avelino et al., 2013), permite que a RNA seja programada em qualquer linguagem de programação ou embarcada em controladores, facilitando o seu uso em tempo real em condições de produção comercial.

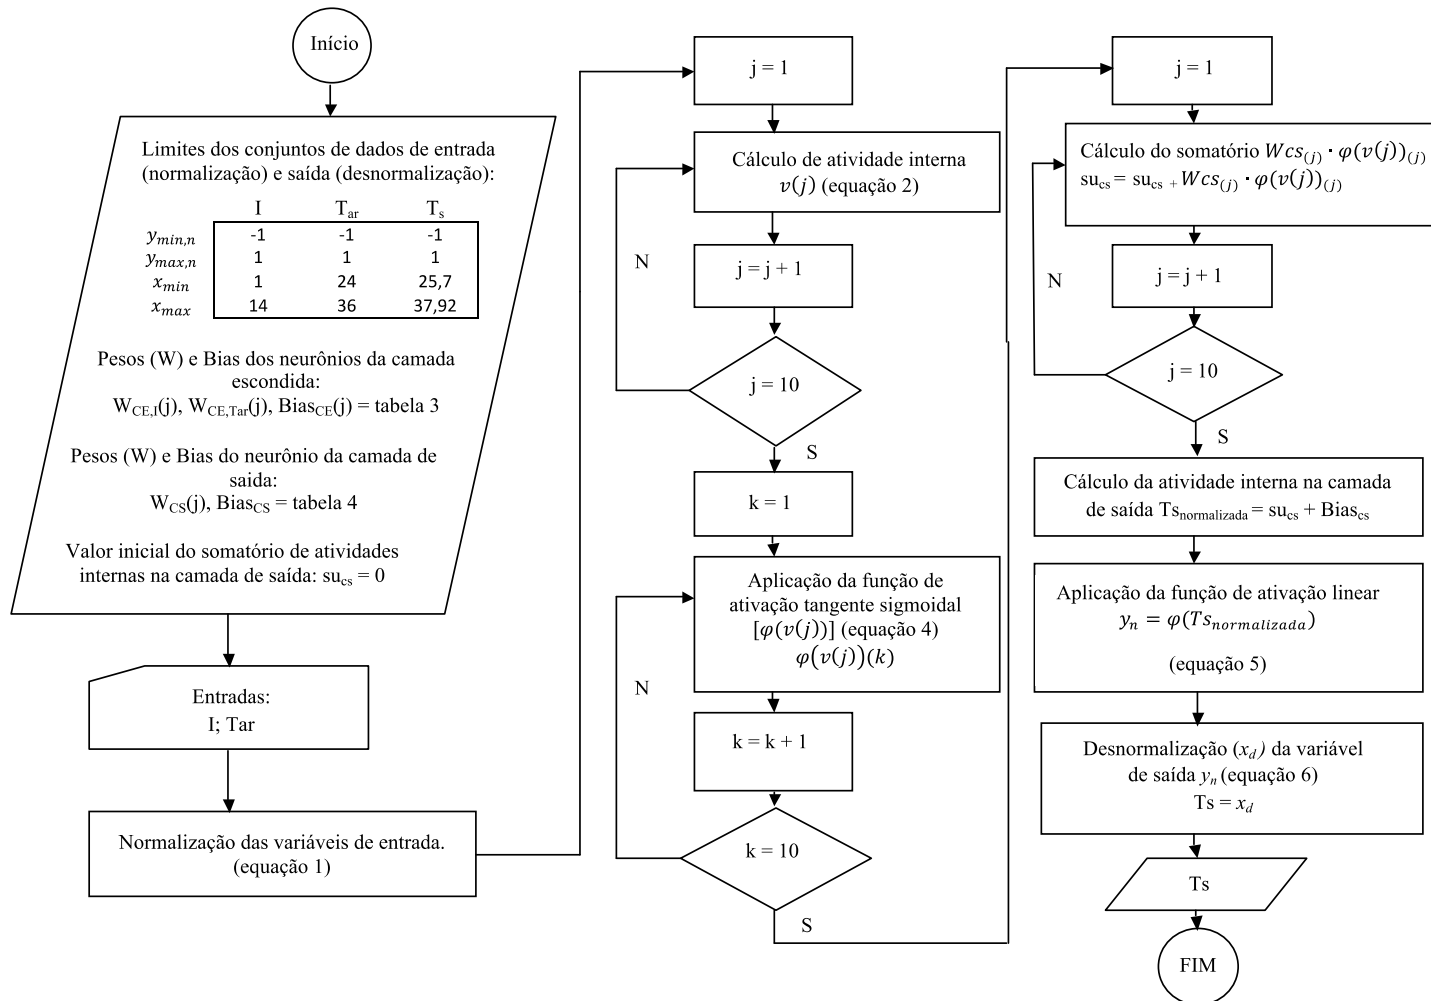


Figura 3. Fluxograma do algoritmo para implementação da RNA para predição da temperatura superficial de frangos de corte.

IV. CONCLUSÃO

A rede neural artificial *multilayer-perceptron* (RNA-MLP) de melhor desempenho treinada, testada e validada nesta pesquisa, permite a predição da temperatura superficial de frangos de corte da linhagem Cobb, de 1 a 14 dias de idade, em função da idade da ave e da temperatura do ar. A RNA-MLP obteve desempenho adequado, similar ao de alguns modelos desenvolvidos em outras pesquisas, podendo, desta forma, ser usada em predições e embarcado em sistemas de controle de aquecimento em aviários comerciais para criação de frangos de corte. A RNA obtida é uma rede simples, de fácil implementação, que pode ser usada para monitoramento remoto e em tempo real e, ainda, ser implementada por meio de tecnologias de baixo custo, *open software* e *open hardware*.

AGRADECIMENTOS

Agradecimento à CAPES, CNPq (Processo CNPq 307746/2014-3) e FAPEMIG pelo apoio financeiro.

REFERÊNCIAS

Abreu, L. H. P. (2015). Inteligência artificial na avaliação de respostas produtivas e fisiológicas de frangos de corte submetidos a diferentes intensidades e durações de estresse térmico. 2015. Universidade Federal de Lavras (Master's thesis), Lavras.

Abreu, L. H. P.; Yanagi Junior, T.; Fassani, E. J.; Campos, A. T.; Lourençoni, D. (2015). Fuzzy modeling of broiler performance, raised from 1 to 21 days, subject to heat stress. *Engenharia Agrícola* 35(6) 967-978.

Ahmadi, H., & Golian, A. (2010). The integration of broiler chicken threonine responses data into neural network models. *Poultry science* 89(11) 2535-2541.

- Avelino, A. M.; Rêgo, S. D. P.; Amorim, L. G. D. P.; & Fernandes, J. D. (2013). Monitoramento de ativos hospitalares através de uma rede de sensores sem fio. *Revista Brasileira de Inovação Tecnológica em Saúde* 2(4) 2236-1103.
- Bacurau, R. M.; Leal, B. G.; Ferreira, S. A. (2011). Sistema Eletrônico para Controle e Monitoramento Remoto de Estações Elevatórias de Sistemas Urbanos de Distribuição de Água. ERBASE-Escola Regional de Computação Bahia Alagoas Sergipe, Salvador-BA.
- Campos, A. T.; Castro, J. D. O.; Schiassi, L.; Yanagi Junior, T.; Pires, M. D. F. Á. ; Mattioli, C. C. (2013) Prediction of free-stall occupancy rate in dairy cattle barns through fuzzy sets. *Engenharia Agrícola* 33(6) 1079-1089.
- Cony, A. V.; Zocche, A. T. Manejo de frangos de corte (2004). In: Mendes, A.; Nääs, I. D. A.; Macari, M. (Ed.). *Produção de frangos de corte*. Campinas: Facta, 118-136
- Demirel, H.; Gökteş, H. H.; Erkal, B.; & Ciyilan, B. (2012). Prediction of the brain temperature from other body temperatures in hypothermia induced rats by using artificial neural networks. *Computers in biology and medicine* 42(7) 772-777.
- Faridi, A.; France, J.; & Golian, A. (2013). Neural network models for predicting early egg weight in broiler breeder hens. *Journal of Applied Poultry Research*, 22(1), 1-8.
- Faridi, A., Gitoee, A., Sakomura, N. K., Donato, D. C. Z., Gonsalves, C. A.; Sarcinelli, M. F., France, J. (2016). Broiler responses to digestible total sulphur amino acids at different ages: a neural network approach. *Journal of applied animal research* 44 (1) 315-322.
- Ferraz, P. F. P.; Yanagi Junior, T.; Lima, R. R. D.; & Xin, H. (2017). Performance of chicks subjected to thermal challenge. *Pesquisa Agropecuária Brasileira* 52(2) 113-120.
- Ferraz, P. F. P.; Yanagi Junior, T.; Julio, Y. F. H.; Castro, J. D. O.; Gates, R. S., ... & Campos, A. T. (2014). Predicting chick body mass by artificial intelligence-based models. *Pesq. agropec. bras., Brasília* 49(7) 559-568.
- Ferreira, C. D. P.; Casatti, L. (2006). Integridade biótica de um córrego na bacia do Alto Rio Paraná avaliada por meio da comunidade de peixes. *Biota Neotropica*, 6(3).
- Ferreira, L.; Yanagi Junior, T.; Lopes, A. Z.; Lacerda, W. S. (2010). Desenvolvimento de uma rede neuro-fuzzy para predição da temperatura retal de frangos de corte. *Revista de Informática Teórica e Aplicada* 17(2) 221-233.
- Ferreira, L.; Yanagi Junior, T.; Lacerda, W. S.; Rabelo, G. F. (2012). A fuzzy system for rectal temperature prediction of broiler chickens. *Ciência Rural (UFSC)* 42(1) 1/CR-4377-6.
- Fiorin, D. V.; Martins, F. R.; Schuch, N. J.; Pereira, E. B. (2011). Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares. *Revista Brasileira de Ensino de Física* 33(1) 1309.

- Gitoe, A.; Faridi, A.; France, J. (2017). Mathematical models for response to amino acids: estimating the response of broiler chickens to branched-chain amino acids using support vector regression and neural network models. *Neural Computing and Applications* 1-10.
- Hernández-Julio, Y. F.; Yanagi Junior, T.; Pires, M. D. F. Á.; Lopes, M. A.; Lima, R. R. D. (2014). Models for Prediction of Physiological Responses of Holstein Dairy Cows. *Applied Artificial Intelligence* 28(8) 766-792.
- Julio, Y. F. H.; Yanagi Junior, T.; Pires, M. F. A.; Lopes, M. A.; Lima, R. R. (2015). Fuzzy system to predict physiological responses of Holstein cows in southeastern Brazil. *Revista Colombiana de Ciencias Pecuarias* 28(1) 42-53.
- Kantardzic, M. *Data mining: concepts, models, methods, and algorithms* (2011). New Jersey: John Wiley & Sons, 2nd edition, p.53
- Karadurmus, E.; Cesmecci, M.; Yuceer, M.; & Berber, R. (2012). An artificial neural network model for the effects of chicken manure on ground water. *Applied Soft Computing* 12(1) 494-497.
- Kawakami, E.; Vazzoler, G. (1980). Método gráfico e estimativa de índice alimentar aplicado no estudo de alimentação de peixes. *Boletim do Instituto oceanográfico* 29(2) 205-207.
- Klassen, T.; Martins, T. D.; Cardozo Filho, L.; Silva, E. A. D. (2009). Modelagem do sistema de resfriamento por imersão de carcaças de frangos utilizando redes neurais artificiais-DOI: 10.4025/actascitechnol.v31i2.3358. *Acta Scientiarum. Technology* 31(2) p. 201-205.
- Levenberg, K. (1944) A method for the solution of certain non-linear problems in least squares. *Quarterly of applied mathematics* 2(2) p. 164-168.
- Lopes, A. Z. ; Yanagi Junior, T.; Lacerda, W. S. ; RABELO, G. (2014). Predicting Rectal Temperature of Broiler Chickens with Artificial Neural Network. *IJET: International Journal of Engineering & Technology* 14(5) 29-34.
- Marquardt, D. W. (1963) An algorithm for least-squares estimation of nonlinear parameters. *Journal of the society for Industrial and Applied Mathematics* 11(2) p. 431-441
- Michael, K., Garcia-Souto, M. D. P., Dabnichki, P. (2017). An investigation of the suitability of Artificial Neural Networks for the prediction of core and local skin temperatures when trained with a large and gender-balanced database. *Applied Soft Computing*, 50, 327-343.
- 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.
- Menegali, I.; Tinôco, I. F. F.; Carvalho, C. D. C. S.; Souza, C. D. F.; Martins, J. H. (2013).

Comportamento de variáveis climáticas em sistemas de ventilação mínima para produção de pintos de corte. *Revista Brasileira de Engenharia Agrícola e Ambiental* 17(1) 106-113.

Mottaghitalab, M.; Faridi, A.; Darmani-Kuhi, H.; France, J.; & Ahmadi, H. (2010). Predicting caloric and feed efficiency in turkeys using the group method of data handling-type neural networks. *Poultry science* 89(6) 1325-1331.

Moura, D. J. D.; Maia, A. P. D. A.; Vercellino, R. D. A.; Medeiros, B. B.; Sarubbi, J.; & Griska, P. R. (2011). Uso da termografia infravermelha na análise da termorregulação de cavalo em treinamento. *Engenharia Agrícola, Jaboticabal*, 31(1) 23-32.

Nazareno, A. C., SILVA, I. J. D., Fernandes, D. P. (2016). Prediction of mean surface temperature of broiler chicks and load microclimate during transport. *Engenharia Agrícola*, 36(4), 593-603.

Oliveira, A. C. S. D.; Souza, A. A. D.; Lacerda, W. S.; Gonçalves, L. R. (2010). Aplicação de redes neurais artificiais na previsão da produção de álcool. *Ciênc, agrotec., Lavras* 34(2) 279-284.

Pandorfi, H.; Silva, I. J. O.; Sarnighausen, V. C. R.; Vieira, F. M. C.; Nascimento, S. T.; Guiselini, C. (2011). Uso de redes neurais artificiais para predição de índices zootécnicos nas fases de gestação e maternidade na suinocultura. *Revista Brasileira de Zootecnia* 40(3) 676-681

Ponciano, P. F. ; Yanagi Junior, T.; Schiassi, L.; Campos, A. T. ; Nascimento, J. W. B. (2012). Sistema fuzzy para predição do desempenho produtivo de frangos de corte de 1 a 21 dias de idade. *Engenharia Agrícola*, 32(3) 446-458.

Ponciano, P. F. ; Yanagi Junior, T.; Julio, Y. F. H. ; Castro, J.O. ; Gates, R. S. ; Reis, G. M. ; Campos, A. T. (2014). Predicting chick body mass with artificial intelligence-based models. *Pesquisa Agropecuária Brasileira* 49(7) 559-568.

Schiassi, L. ; Yanagi Junior, T.; Ferreira, Leandro ; Damasceno, F. A. ; Yanagi, S. D. N. M. (2008). Metodologia fuzzy aplicada à avaliação do aumento da temperatura corporal em frangos de corte. *Engenharia na Agricultura* 16(2) 180-191.

Schiassi, L.; Yanagi Junior, T.; Abreu, L. H. P.; Reis, G. M.; Damasceno, F. A.; Silva, G. C. A.; Campos, A. T. (2014). Laboratory Proposal for Studies on Poultry Environment. *International Journal of Engineering Research and Applications (IJERA)* 4(9) 65-74.

Sjöberg, J.; Ljung, L. (1992) Overtraining, regularization, and searching for minimum in neural networks. *IFAC Proceedings Volumes*, 25(14), pp.73-78.

Tao, X.; Xin, H. (2003). Acute synergistic effects of air temperature, humidity, and velocity on homeostasis of market-size broilers. *Transactions of the ASAE* 46(2) 491.

Turi, B. C.; Codogno, J. S.; Fernades, R. A.; Amaral, S. L. D.; Monteiro, H. L. (2012). Frequência de ocorrência de doenças crônico degenerativas em adultos com mais de 50 anos. *Revista Brasileira de Atividade Física & Saúde* 15(4) 218-223.

Yanagi Junior, T.; XIN, H.; Gates, R. S. (2003). Eficácia do molhamento superficial, parcial e intermitente de galinhas poedeiras submetidas ao estresse térmico agudo. *Revista Engenharia Agrícola, Jaboticabal* 23(2) 233-242.

Yanagi Junior, T.; Ferreira, L.; Nääs, I. A.; Lopes, M. A. (2007). Development of Algorithm Using Fuzzy Logic to Predict Estrus in Dairy Cows: Part I. E-journal. *International Commission of Agricultural Engineering IX* 1-16.