



# ESTUDO DA INFLUÊNCIA DE FATORES AMBIENTAIS EM VARIÁVEIS FISIOLÓGICAS DE FRANGOS DE CORTE COM REDES NEURAIS ARTIFICIAIS

Kelly Botigeli Sevegnani<sup>1</sup>, Silvia Helena Modenese-Gorla da Silva<sup>2</sup>, Danielle Priscila Bueno Fernandes<sup>3</sup> & Iran José Oliveira da Silva<sup>4</sup>

**RESUMO:** Este trabalho investiga o uso de Redes Neurais Artificiais (RNAs) na análise da influência de fatores ambientais em diversos parâmetros fisiológicos em frangos de corte. Os dados deste trabalho foram obtidos em câmara climática do Núcleo de Pesquisa em Ambiência - NUPEA/ESALQ/USP. Machos e fêmeas de frangos de corte da linhagem Ross com 21, 28, 35, 42 e 49 dias de idade foram submetidos a quatro combinações de temperatura e umidade relativas. As RNAs foram utilizadas para avaliação da influência e relação de variáveis tais como temperatura, umidade relativa, frequência respiratória, temperatura retal, idade, ganho de peso, tempo de permanência no comedouro e tempo de permanência no bebedouro. Os resultados mostraram que é difícil prever a condição ambiental a qual o animal foi submetido pelo conjunto de dados. O menor erro foi obtido com a variável ganho de peso como saída, sugerindo que esta seja a mais fortemente correlacionada com as outras variáveis.

**PALAVRAS-CHAVE:** Redes Neurais Artificiais, avicultura, ambiência.

## STUDY OF THE INFLUENCE OF ENVIRONMENTAL FACTORS IN BROILER USING ARTIFICIAL NEURAL NETWORKS

**ABSTRACT:** This work investigates the use of Artificial Neural Networks to analyse the influence of ambient variables in broilers. Data was obtained in the climatic chamber of Nucleous of Bioclimatology Research (NUPEA/ESALQ/USP). Broilers (males and females) of Ross genetic with 21, 28, 35, 42 e 49 day-old were submitted to four combinations of temperature and relative humidity. Artificial Neural Networks were applied to evaluation of the influence and correlation of variables such as temperature, relative humidity, respiratory frequency, retal temperature and age in the weight gain of broilers. The results showed that it is difficult to predict the environmental conditions that the animal was subjected by the data set. The smallest error was obtained with the variable weight gain as output, suggesting that this one is the most strongly correlated with the other variables.

**KEYWORDS:** Artificial Neural Networks, poultry production, bioclimatology.

## 1 INTRODUÇÃO

O Brasil é hoje o terceiro maior produtor mundial de frangos de corte e a partir de 2004, se tornou o primeiro em exportação (antes ocupada pelos Estados Unidos). Em 2014 a produção de carne de frango foi de 12,7 milhões de toneladas. Além disso, o consumo per capita de frango no Brasil foi de 42,78 kg, tendo alcançado a marca de 47,38 em 2011, (ABPA, 2017).

Nos últimos anos, o aumento da importância do consumidor em relação ao bem-estar animal, refletiu em maiores exigências dos importadores, das redes de supermercados e da cadeia de comidas rápidas. Por esta razão, empresas produtoras foram obrigadas a implementar programas de qualidade, de bem-estar e de

rastreabilidade para atender as exigências do mercado (UBA, 2008).

Desta forma, a preocupação em atingir níveis de bem-estar para que a produção seja maximizada vem ganhando maior importância pela complexidade com que os fatores de produção estão correlacionados.

Como ambiente de criação, consideraram-se todas as condições físicas das instalações, os sistemas de controle do microclima interno, as condições de manejo e equipamentos e as condições de nutrição e sanidade adotadas em cada tipo de criação (SILVA *et al.* 2011).

A manutenção do conforto térmico dentro dos aviários é um dos problemas enfrentados pelos produtores avícolas. As aves respondem de maneira diferente dependendo da condição de temperatura e umidade relativa internas. A ingestão de ração e água são influenciadas também pelas mesmas condições.

A eficiência na produção de frangos de corte é afetada

<sup>1</sup> e <sup>2</sup> UNESP - Campus de Registro. E-mail: [kelly@registro.unesp.br](mailto:kelly@registro.unesp.br) ; [silvia@registro.unesp.br](mailto:silvia@registro.unesp.br)

<sup>3</sup> e <sup>4</sup> ESALQ/USP. E-mail: [dani.fernandes@registro.unesp.br](mailto:dani.fernandes@registro.unesp.br) ; [ijosilva@usp.br](mailto:ijosilva@usp.br)

pelo estresse calórico em países tropicais como o Brasil. Seu efeito é economicamente significativo apesar da duração variável desse estado de estresse, dependendo das condições ambientais.

Durante o estresse pelo calor há redução na eficiência da utilização dos alimentos. Esta redução pode ser devida à digestibilidade alimentar mais baixa, a primeira etapa da utilização do alimento (LAGANÁ, 2005).

O controle e o monitoramento da produção animal são menos desenvolvidos quando comparados com os utilizados na indústria. Muitos sistemas contendo alguns elementos de sistemas de monitoramento integrados já estão disponíveis comercialmente para suínos, aves e produção leiteira. Esses sistemas têm o potencial de aumentar a eficiência na produção e no controle de qualidade nas fazendas e tornar os produtores mais capacitados a responder as pressões do comércio sobre seus produtos (AERTS *et al.*, 2003).

No trabalho de Kalhor *et al.*, (2016), as RNAs foram usadas para calcular a taxa de energia produzida a partir de valores de entrada. Os dados foram coletados em 40 granjas de produção de frangos. O grau de incerteza destes dados, aliado à sua grande variação torna impraticável a codificação de algoritmos específicos.

Técnicas de Aprendizado de Máquina, AM, por serem capazes de aprender por si próprias (MITCHEL, 1997), representam uma alternativa atraente para lidar com este tipo de problema.

Silva (2016), trabalhou no desenvolvimento de uma metodologia que validasse o sistema de ventilação por exaustores em aviários, obtendo resultados satisfatórios na simulação dos equipamentos.

Dentro da área de AM, uma das técnicas que se destaca são as Redes Neurais Artificiais (RNAs). As RNAs se baseiam em uma forma de computação não algorítmica, cujo funcionamento é inspirado no cérebro humano (BRAGA *et al.*, 2007). Pode-se buscar melhores resultados utilizando-se as RNAs em comitês ou *ensembles*, ou seja, a combinação de estimadores, baseados em redes neurais, buscando melhores resultados, do que quando utilizado um único estimador.

Alguns trabalhos com o uso de RNAs na avicultura podem ser citados.

Schiassi (2015) analisou o efeito da idade e da temperatura do ar nos parâmetros de produção de frangos de corte com 1 a 21 dias de idade, utilizando um modelo matemático Fuzzy com os animais em túnel de vento climatizado cujos resultados observados foram utilizados no do modelo calculando-se o consumo de ração, ganho de peso e conversão alimentar.

Sidney (2011) estudou a predição do ganho de peso de frangos de corte durante as primeiras três semanas de vida utilizando uma rede neural artificial que teve como

dados de entrada a idade do frango (semanas), a temperatura (°C) e a umidade relativa do ar (%) no ambiente de criação, e, como variável de saída o ganho de peso dos animais (g). A rede neural proposta mostrou-se adequada em aproximar os ganhos de peso de frangos na fase de aquecimento.

Em Salle *et al.* (2010), as RNAs foram utilizadas para a classificação do comportamento bioquímico de amostras de *Escherichia coli* isoladas de frangos de corte.

Neste trabalho, o objetivo foi aplicar as Redes Neurais Artificiais para avaliar e relacionar a influência das variáveis climáticas na variação do peso corporal dos frangos de corte submetidos a situações de estresse em câmara climática. Também foi analisado, em uma parte do experimento, o desempenho das RNAs em comitês.

Este artigo encontra-se organizado como segue: a Seção 2 descreve as técnicas de aprendizado e de comitês empregadas neste trabalho. A Seção 3 apresenta os materiais e métodos utilizados nos experimentos conduzidos. A Seção 4 lista e discute os resultados obtidos. Finalizando, a Seção 5 conclui este artigo.

## 2 TÉCNICAS UTILIZADAS

Esta seção descreve as técnicas utilizadas nos experimentos realizados neste trabalho.

### 2.1 REDES NEURAS ARTIFICIAIS

As RNAs se baseiam em uma forma de computação não algorítmica, cujo funcionamento é inspirado no cérebro humano. As RNAs podem ser definidas como sistemas paralelos distribuídos compostos de unidades de processamento simples que computam determinadas funções matemáticas. Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria dos modelos estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede (BRAGA *et al.*, 2007).

A solução de problemas através de RNAs é bastante atrativa, já que a forma como estes são representados internamente pela rede e o paralelismo natural inerente à arquitetura das RNAs criam a possibilidade de um desempenho superior àquele obtido pelos modelos convencionais. Em RNAs, o procedimento usual na solução de problemas passa inicialmente por uma fase de aprendizagem, onde um conjunto de exemplos é apresentado para a rede, a qual extrai automaticamente as características necessárias para representar a informação fornecida. Essas características são utilizadas posteriormente para gerar respostas para novos dados.

### 2.2 COMBINAÇÃO DE ESTIMADORES

Entende-se por combinação de estimadores a união de vários estimadores independentes com o objetivo de

aproveitar as características intrínsecas de cada um deles para a resolução de um dado problema. A combinação de estimadores tem sido empregada com sucesso em diversos problemas de reconhecimento de padrões. Neste caso, o baixo desempenho de um estimador para alguns padrões pode ser compensado por um melhor desempenho obtido por um outro estimador para um subconjunto destes padrões.

A combinação deve utilizar estimadores independentes, mas que sejam eficientes para resolver o problema a ser tratado. Desta forma, a combinação tem por objetivo melhorar o desempenho no que diz respeito à obtenção de melhores taxas de reconhecimento bem sucedido e uma maior estabilidade nas respostas fornecidas (DIETTERICH, 1997).

Na área de reconhecimento de padrões, é cada vez mais defendida a ideia de que um sistema de múltiplos estimadores possa levar a uma maior eficiência ao tratar com problemas mais complexos, como, por exemplo, reconhecimento de caracteres manuscritos. Múltiplos estimadores frequentemente utilizam diferentes conjuntos de características e métodos de classificação, o que pode contribuir para uma taxa de reconhecimento mais elevada. De acordo com Sharkey (2012), existem dois tipos de combinações:

- Combinação de módulos: cada componente lida com uma subtarefa da tarefa a ser atacada;
- Combinação de estimadores: diferentes métodos são utilizados para resolver a mesma tarefa, também conhecidos como comitês ou *ensembles*.

Para a combinação de estimadores, um método se destaca: *Bagging* (Breiman, 1996). Esse método utiliza técnicas de amostragem para obter conjuntos diferentes de treinamento para cada um dos classificadores (OPTIZ E MACLIN, 1999).

*Bagging* é um método de comitê do tipo *bootstrap* (CHERNIK, 2011) que cria componentes para seu comitê treinando cada classificador através da redistribuição aleatória de conjuntos de treinamento. Cada classificador individual no comitê é gerado com uma amostragem aleatória diferente do conjunto do treinamento original.

No *Bagging*, a amostragem de conjunto do treinamento não é dependente do desempenho de classificadores mais avançados.

### 3 MATERIAL E MÉTODOS

Esta seção descreve a maneira como foi conduzido o experimento.

#### 3.1 BASE DE DADOS

A base de dados deste trabalho foi obtida na câmara

climática do Núcleo de Pesquisa em Ambiente, na ESALQ/USP, em Piracicaba, SP. O experimento foi dividido em 04 boxes de 1m<sup>2</sup> cada um. Cada box foi equipado com um bebedouro pendular automático e um comedouro pendular de abastecimento manual, ambos da marca Avemarau, além de cobertura para a cama de 10 cm de casca de arroz, material comumente usado para este fim, em aviários comerciais.

Foram utilizadas aves da linhagem Ag Ross, criadas em lotes mistos, nas idades de 21, 28, 35, 42 e 49 dias. A Tabela 1 descreve o conjunto de dados, apresentando o número total de padrões (aves) e o número de atributos contínuos e discretos e se há valores ausentes para alguns atributos. Os atributos utilizados para o treinamento da RNA foram temperatura retal, frequência respiratória, tempo de permanência no bebedouro, tempo de permanência no comedouro, idade, variação do ganho de peso do animal e 4 condições de estresse (Tabela 2).

**Tabela 1- Descrição do conjunto de dados.**

Padrões (n° de aves)	Atributos * (cont., disc.)	Valores ausentes
400	7 (5,2)	Não

\* Temperatura retal, frequência respiratória, tempo de permanência no comedouro e no bebedouro.

**Tabela 2- Condições de alojamento (combinações de temperaturas e umidades relativas impostas na câmara climática.**

Condições de alojamento	Temperatura e Umidade Relativa
I	28° C e 60%
II	31° C e 65%
III	34° C e 70%
IV	37° C e 75%

Foram testadas 4 hipóteses diferentes, 1 problema de classificação e 3 problemas de regressão:

- Nesta primeira hipótese, foi verificado se de acordo as variáveis fisiológicas, tais como, temperatura retal, frequência cardíaca, ganho de peso e idade e, também, tempo de permanência no comedouro e tempo de permanência no bebedouro, consegue-se prever a condição de estresse (Tabela 2) a que o animal foi submetido;
- Testou-se como saída o tempo de permanência no comedouro;
- Testou-se como saída o tempo de permanência no bebedouro;
- Verificou-se se as variáveis influenciam no ganho de peso do animal (saída). Nesta hipótese foi verificado, também, o desempenho das RNAs em comitês.

A seguir, a descrição da metodologia utilizada para executar o experimento.

### 3.2 METODOLOGIA

Os resultados foram obtidos utilizando *10-fold cross validation* (MITCHELL, 1997). O método de amostragem *10-fold cross validation* particiona o conjunto de dados total em 10 partes iguais, utilizando 9 partes para treinar e uma para testar. São realizados, portanto, 10 diferentes treinamentos e testes.

Foram utilizadas RNAs Perceptron multicamadas, treinadas com o algoritmo *backpropagation* (RUMELHART *et al*, 1986), com termo *momentum*. A taxa de aprendizado e o termo *momentum* adotados foram respectivamente iguais a 0,2 e 0,3.

Em relação à técnica de comitê, foi testado o método *Bagging*, utilizando-se como estimador base as RNAs. O comitê formado foi de 10 membros.

Para implementação das RNAs, utilizou-se a ferramenta Weka (*Waikato Environment for Knowledge Analysis*) (WITTEN e FRANK, 2016).

### 4 RESULTADOS E DISCUSSÕES

Primeiramente, foi analisado o problema de classificação. A Tabela 3 apresenta a matriz de confusão com distribuição média de acertos para cada condição (I, II, III e IV) de acordo com os conjuntos de teste.

**Tabela 3 – Matriz de Confusão com as taxas de acerto médio e desvio padrão obtidos para cada classe, de acordo com os conjuntos de teste.**

I	II	III	IV
<b>64,03</b>	31,52	2,33	2,11
24,27	<b>54,4</b>	15,45	5,87
7,56	31,15	<b>34,23</b>	27,06
1	11,91	28,97	<b>58,12</b>

De acordo com a Tabela 3 e com as taxas de acerto médio dos conjuntos de teste, mostradas na Tabela 4, verificou-se que, de acordo com as variáveis de entrada analisadas, é difícil prever a qual condição ambiental o animal foi submetido. Pelos resultados, mostrados na Tabela 3, verifica-se que as condições I e II estão mais próximas. O mesmo acontece com as condições III e IV. Também se verificou uma proximidade entre as condições II e III.

**Tabela 4 – Taxas de acerto e desvio padrão dos conjuntos de teste para o experimento de classificação.**

Taxa de acerto médio	Desvio padrão
50%	7,07

Por sua vez, as taxas do erro quadrático médio e desvio padrão para os problemas de regressão, os quais se

verificou a influência das variáveis ambientais e fisiológicas no tempo de permanência no comedouro, no bebedouro e no ganho de peso do animal, são demonstradas na Tabela 5.

**Tabela 5 – Erro quadrático médio e desvio padrão para os experimentos com tempo de permanência no comedouro, tempo de permanência no bebedouro e ganho de peso do animal.**

Comedouro (min)	Bebedouro (min)	Ganho de Peso (gramas)
30,51±3,83	27,10±4,20	<b>RNA</b> 13,00±6,12
		<b>Bagging</b> 11,50±6,38

De acordo com a Tabela 5, verifica-se que o experimento que apresentou menor erro quadrático médio foi aquele com o ganho de peso do animal como saída. Sugere-se que o ganho de peso do animal esteja mais fortemente correlacionado com as variáveis ambientais e fisiológicas.

As variáveis tempo de permanência no comedouro e tempo de permanência no bebedouro, por sua vez, quando utilizadas como saída, mostraram menor correlação com as variáveis analisadas.

Verifica-se, também, na Tabela 5, que as RNAs quando utilizadas em comitê apresentam uma taxa de erro menor do que quando utilizadas como estimador individual.

Amraei *et al.* (2017) alcançou resultados similares trabalhando com frangos de 1 a 42 dias de idade na simulação de ganho de peso a partir de variáveis fisiológicas. Os resultados mostraram forte correlação entre o ganho de peso como variável de saída e as variáveis de entrada.

### 5 CONCLUSÕES

O uso das Redes Neurais Artificiais na avaliação da influência das variáveis climáticas na variação do peso corporal dos frangos mostrou-se eficiente, tendo sido a variável fisiológica mais fortemente correlacionada com as variáveis climáticas.

O *Bagging* apresentou menor taxa de erro quadrático médio do que quando a RNA foi utilizada como um único estimador. Foi também possível a predição da condição de estresse a que o animal foi submetido em função das variáveis fisiológicas.

Um inconveniente do experimento com as RNAs é que não se conseguiram as funções de predição. Isto mostra a necessidade de uma investigação maior envolvendo o uso de outras técnicas de Aprendizado de Máquina e estatísticas para buscar conhecer melhor a influência de cada variável, bem como a função que a descreve.

## 6 REFERÊNCIAS

- AERTS, J.-M.; WATHES, C. M.; BERCKMANS, Daniel. Dynamic data-based modelling of heat production and growth of broiler chickens: development of an integrated management system. **Biosystems Engineering**, v. 84, n. 3, p. 257-266, 2003.
- AMRAEI, S.; ABDANAN MEHDIZADEH, S.; SALARI, S. Broiler weight estimation based on machine vision and artificial neural network. **British poultry science**, v. 58, n. 2, p. 200-205, 2017.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B.. Redes Neurais Artificiais – Teoria e Aplicações, 2ª edição: Editora LTC, 2007, 226 p.
- BREIMAN, L. Bagging Predictors. **Machine Learning**, v.24, n. 2, p. 123-140, 1996.
- DIETTERICH, T. G. Machine learning research: Four current directions. **AI Magazine**, v. 118, n.4, p. 97-136. 1997.
- DO NASCIMENTO, Guilherme R. et al. Termografia infravermelho na estimativa de conforto térmico de frangos de corte. **R. Bras. Eng. Agríc. Ambiental**, v. 18, n. 6, p. 658-663, 2014.
- FROST, A. R. et al. Progress towards the development of an integrated management system for broiler chicken production. **Computers and Electronics in Agriculture**, v. 39, n. 3, p. 227-240, 2003.
- CHERNICK, M. R. et al. **Bootstrap methods**. Springer Berlin Heidelberg, 2011.
- GATES, R. S.; XIN, H (2001). Comparative analysis of measurement techniques of feeding behaviour of individual poultry. Paper nº: 01-4033. ASAE, St. Joseph, p 1-12.
- KALHOR, T. et al. Modeling of energy ratio index in broiler production units using artificial neural networks. **Sustainable Energy Technologies and Assessments**, v. 17, p. 50-55, 2016.
- LAGANÁ, C. **Otimização da produção de frangos de corte em condições de estresse por calor**. 180f. Tese (Doutorado) – Universidade Federal do Rio Grande do Sul, 2005.
- MITCHELL, T. M. **Machine learning**. Boston: McGraw Hill Companies Inc., p.414 1997.
- OPTIZ, D.; MACLIN, R. Popular ensemble methods. An empirical study. **Journal of Artificial Intelligence Research** 11, p.169-198. 1999.
- RUMELHART, D. E.; HINTON, G. E., WILLIAMS, R. J. Learning representations by back-propagation errors. **Nature**, London, UK, v. 323: p. 533 – 536, 1986.
- SALLE, F. O.; FORTES, F. B. B.; ROCHA, A. C. G. P.; ROCHA, S. L. F.; SOUZA, G. F.; MORAES, H. L. S.; MORAES, L. B.; SALLE, C. T. P. Utilização de inteligência artificial (redes neurais artificiais) para a classificação do comportamento bioquímico de amostras de *Escherichia coli* isoladas de frangos de corte. **Acta Scientiae Veterinariae**. V. 38, n. 1, p. 59-62. 2010.
- SCHIASSI, Leonardo et al. Modelagem Fuzzy aplicada na avaliação do desempenho de frangos de corte. **R. Bras. Eng. Agríc. Ambiental**, v. 19, n. 2, p. 140-146, 2015.
- SHARKEY, A. J. C (Ed.). **Combining artificial neural nets: ensemble and modular multi-net systems**. Springer Science & Business Media, 2012.
- SIDNEY, L. H. F. **Utilização de redes neurais artificiais para a aproximação de ganhos de peso de frangos de corte**. 48f. Dissertação (Mestrado). Universidade Federal de Lavras. Lavras, MG, 2011.
- SILVA, M. A. P.; ROSADO, P. L.; BRAGA, M. J.; CAMPOS, A. C. Oferta de exportação de carne de frango do Brasil, de 1992 a 2007. **Rev. Econ. Sociol. Rural** [online]. 2011, vol.49, n.1, pp. 31-53.
- SILVA, W. T. et al. Sistema automatizado para avaliação de exaustores em galpões climatizados. 2016. Disponível em: <<http://repositorio.unicamp.br/handle/REPOSIP/305368>> Acesso em: 17/06/2017.
- UBA - União brasileira de avicultura. Protocolo de bem-estar para frangos e perus. São Paulo, jun. 2008. Disponível em: [http://avisite.com.br/legislacao/anexos/protocolo\\_de\\_bem\\_estar\\_para\\_frangos\\_e\\_perus.pdf](http://avisite.com.br/legislacao/anexos/protocolo_de_bem_estar_para_frangos_e_perus.pdf)<<http://www.uba.org.br>>. Acesso em: 16 jun. 2017.
- UBA - União Brasileira de Avicultura ABPA (Associação Brasileira de Proteína Animal). Disponível em: <<http://abpa-br.com.br/setores/avicultura/mercado-interno/frango>>. <http://www.abef.com.br/ubabef/exibnoticiaubabef.php?notcodigo=3113>. Acesso em: 16 jun. 2017.
- WITTEN, I. H. et al. **Data Mining: Practical machine learning tools and techniques**. Morgan Kaufmann, 2016.