

# Redes neurais artificiais para o gerenciamento da indústria avícola: uma simulação baseada na cadeia de produção de frangos de corte

## Artificial neural networks for the management of poultry industry: a simulation based on the broiler production chain

Elisar Camilotti<sup>1</sup> , Thales Quedi Furian<sup>1</sup> , Karen Apellanis Borges<sup>1\*</sup> , Daniela Tonini da Rocha<sup>1</sup> , Vladimir Pinheiro do Nascimento<sup>1</sup> , Hamilton Luiz de Souza Moraes<sup>1</sup> , Carlos Tadeu Pippi Salle<sup>1</sup> 

<sup>1</sup>Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, Rio Grande do Sul, Brasil

\*Autor correspondente: [karen.borges@ufrgs.br](mailto:karen.borges@ufrgs.br)

### Resumo

O objetivo deste trabalho foi prever os indicadores de produção e determinar o seu potencial impacto econômico em um sistema de integração utilizando as redes neurais artificiais (RNA). Quarenta parâmetros zootécnicos e de produção de granjas de matrizes e de frango de corte, um incubatório e um abatedouro foram selecionados como variáveis. Os modelos de RNA foram estabelecidos para quatro variáveis de saída (“eclosão vendável”, “peso ao final da quinta semana”, “condenações parciais” e “condenações totais”) e foram analisados em relação ao coeficiente de determinação múltipla ( $R^2$ ), coeficiente de correlação (R), erro médio (E), erro quadrático médio (EQM) e raiz do erro quadrático médio (REQM). Os cenários produtivos foram simulados e os impactos foram estimados. Os modelos de RNA gerados foram adequados para simular diferentes cenários produtivos após o treinamento. Para “eclosão vendável”, o modelo de incubadora e o período de incubação aumentaram os ganhos financeiros. Para “peso ao final da quinta semana”, a linhagem também demonstrou influência no retorno financeiro, o que não aconteceu com o peso ao final da primeira semana. O sexo do lote possui influência nas taxas de “condenação parcial”, ao contrário do peso do frango no primeiro dia. As taxas de mortalidade e o peso do frango apresentaram influência na “condenação total”, mas o sexo do lote e o tipo de pinto não tiveram influência.

**Palavras-chave:** gerenciamento de dados; impacto econômico; inteligência artificial; produção avícola

### Abstract

The aim of this study was to predict production indicators and to determine their potential economic impact on a poultry integration system using artificial neural networks (ANN) models. Forty zootechnical and production parameters from broiler breeder farms, one hatchery, broiler production flocks, and one slaughterhouse were selected as variables. The ANN models were established for four output variables: “saleable hatching”, “weight at the end of week 5”, “partial condemnation”, and “total condemnation” and were analyzed in relation to the coefficient of multiple determination ( $R^2$ ), correlation coefficient (R), mean error (E), mean squared error (MSE), and root mean square error (RMSE). The production scenarios were simulated and the economic impacts were estimated. The ANN models were suitable for simulating production scenarios after validation. For “saleable hatching”, incubator and egg storage period are likely to increase the financial gains. For “weight at the end of the week 5” the lineage (A) is important to increase revenues. However, broiler weight at the end of the first week may not have a significant influence. Flock sex (female) may influence the “partial condemnation” rates, while chick weight at first day may not. For “total condemnation”, flock sex and type of chick may not influence condemnation rates, but mortality rates and broiler weight may have a significant impact.

**Keywords:** artificial intelligence; data management; economic impact; poultry production

## 1. Introdução

Apesar das melhorias no desempenho dos índices zootécnicos de lotes de frangos de corte através dos ganhos em genética, nutrição e manejo,

ainda há uma lacuna entre o potencial e a performance alcançada<sup>(1)</sup>. A produção de carne de frango é tipicamente baseada nos manuais das empresas e linhagens avícolas e na experiência do produtor.

Recebido: 27 de fevereiro de 2023. Aceito: 2 de junho de 2023. Publicado: 20 de junho de 2023.



Este é um artigo de Acesso Aberto distribuído sob os termos da Creative Commons Attribution License, que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o trabalho original seja devidamente citado.

<https://revistas.ufg.br/vet/index>

Entretanto, o desenvolvimento de novas tecnologias na última década tem apoiado a tomada de decisão nas granjas avícolas<sup>(2)</sup>. Além disto, estudos epidemiológicos utilizando uma abordagem integrada para identificar os diferentes fatores que ameaçam o desempenho de frangos de corte em condições de campo são raros<sup>(1)</sup>.

A inteligência artificial (IA) foi desenvolvida em conjunto com a necessidade de se analisar um grande volume de dados através da computação de alto desempenho<sup>(3)</sup>. As ferramentas de IA incluem as redes neurais artificiais (RNA), que são sistemas de computação inspirados em redes neurais biológicas que constituem cérebros de animais<sup>(4)</sup>. A RNA é uma ferramenta útil para a classificação, agrupamento, reconhecimento de padrões e predição em diversas áreas, incluindo a produção animal<sup>(5)</sup>. A principal vantagem dos modelos de RNA é que eles consideram a não linearidade da relação entre os dados de entrada e saída<sup>(6)</sup>. Outras propriedades interessantes incluem autoaprendizagem, adaptabilidade e tolerância a falhas<sup>(5)</sup>.

Estudos anteriores conduzidos por nosso grupo de pesquisa demonstraram que a RNA pode ser usada para o gerenciamento de parâmetros de desempenho em diferentes áreas da produção avícola<sup>(3,7-10)</sup>. Além disso, a RNA tem sido utilizada para avaliar a depleção de linfócitos na bolsa de Fabricius e no timo<sup>(3, 11, 12)</sup>. Outros modelos matemáticos e sistemas de inteligência também têm sido desenvolvidos para possibilitar o gerenciamento de dados em diversas áreas da cadeia produtiva avícola<sup>(13-16)</sup>.

A melhoria em produtividade aumenta a competitividade da indústria avícola. Assim, é imprescindível determinar os fatores internos e externos que podem afetar a produção avícola e aumentar o custo ou reduzir a receita. A identificação desses fatores pode subsidiar o estabelecimento de estratégias para melhorar a produtividade<sup>(17)</sup>. O objetivo desse estudo foi avaliar a capacidade dos modelos de RNA em prever os indicadores de produção e entender seu potencial impacto econômico em um sistema de integração avícola.

## 2. Material e métodos

### 2.1 Base de dados

Uma série histórica de dados de granjas de matrizes de frangos de corte, de um incubatório, de lotes de produção de frangos de corte e de um abatedouro de uma única empresa avícola no Rio Grande do Sul (Brasil) foi selecionada para este estudo. Dados de 2.191 lotes e 2 milhões de aves

foram coletados durante um período de sete meses. Quarenta parâmetros zootécnicos e produtivos foram selecionados como variáveis para esse estudo (Tabela 1). A análise descritiva das variáveis está descrita no Material Suplementar (Tabela S1).

### 2.2 Seleção de variáveis de entrada e saída

“Variáveis de entrada” são aqueles parâmetros selecionados para compor um modelo matemático preditivo; “variáveis de saída” referem-se aos indicadores de interesse a serem estimados. Para esse estudo, as variáveis de saída foram definidas com base no interesse da empresa e as variáveis de entrada utilizadas para cada modelo foram selecionadas com base em sua influência, de acordo com a literatura. Modelos de RNA foram estabelecidos para quatro variáveis de saída: (1) eclosão vendável; (2) peso ao final da semana; (3) condenação parcial e (4) condenação total. As variáveis de entrada incluídas em cada modelo são descritas na Tabela 2.

### 2.3 Redes neurais artificiais (RNA)

As variáveis de entrada e saída foram analisadas através do programa *NeuroShell Predictor*<sup>(18)</sup>. O *NeuroShell Predictor* foi usado para prever e estimar valores numéricos. Foram aplicadas as seguintes configurações: (1) estratégia de treinamento, genética; (2) número máximo de neurônios ocultos, 80; (3) meta de otimização, maximizando o R-quadrado; (4) método de otimização, *gene hunter*. Para o treinamento da RNA foi utilizado o método genético, que é uma variação do algoritmo genético da rede neural de regressão geral (RNRG), que é uma técnica de validação cruzada que combina um algoritmo genético com um estimador estatístico. Dados individuais de 1.096 lotes (50% dos registros) foram selecionados aleatoriamente para treinamento. Os demais dados foram utilizados para validação.

### 2.4 Análise dos modelos de RNA

Os modelos de RNA foram analisados individualmente em relação ao coeficiente de determinação múltipla ( $R^2$ ), coeficiente de correlação ( $R$ ), erro médio ( $E$ ), erro quadrático médio (EQM) e raiz do erro quadrático médio (REQM). O EQM é usado na análise de regressão para mostrar a proximidade de uma linha de regressão a um conjunto de pontos (a distância da linha de regressão) e o REQM é o desvio padrão dos resíduos (erros de previsão). Após o treinamento da RNA, o modelo mais ajustado para cada variável foi selecionado e validado. O desempenho do modelo gerado foi analisado com base nos valores de  $R^2$ ,  $R$ ,  $E$ , EQM e REQM.

**Tabela 1.** Parâmetros produtivos e zootécnicos (variáveis) selecionados para o estudo

Variável	Unidade	Número total
Granja	-	n=91
Linhagem das aves	-	A (n=1.821 lotes) B (n=305 lotes) Lotes mistos: A + B (n=64 lotes)
Média de idade dos lotes de matrizes	semana	-
Peso do ovo	g	-
Tipo de ovo	-	Ovo de ninho limpo (n=1.771) Ovo de ninho sujo (n=335) Ovo de cama (n=84)
Período de estocagem dos ovos	h	-
Ovos trincados	%	-
Fertilidade	%	-
Ovos incubáveis	%	-
Modelo de incubadora	-	A (n=936) B (n=1.255)
Período de incubação	min	-
Perda de peso do ovo	g	-
Eclosão total	%	-
Eclosão vendável	%	-
Nascedouros	-	n=38
Número de lotes em cada nascedouro	-	-
Tempo no nascedouro	min	-
Contaminação nascedouro ( <i>Aspergillus</i> spp.)	UFC/10cm <sup>2</sup>	-
Contaminação nascedouro ( <i>Escherichia coli</i> )	UFC/10cm <sup>2</sup>	-
Contaminação nascedouro ( <i>Pseudomonas</i> spp.)	UFC/10cm <sup>2</sup>	-
Contaminação nascedouro ( <i>Salmonella</i> spp.)	UFC/10cm <sup>2</sup>	-
Peso de pinto	g	-
Aproveitamento de pintos	%	-
Contaminação durante transferência	%	-
Tipo de pinto	-	De matrizes < 37 semanas (n=1.145) De matrizes entre 38 a 49 semanas (n=766) De matrizes >49 semanas (n=279)
Sexo do lote	-	Macho (n=983) Fêmea (n=1.117) Lotes mistos (macho e fêmea) (n=4)
Produtor	-	n=138
Profissional	-	n=23
Peso do frango ao final da primeira semana	g	-
Peso do frango ao final da segunda semana	g	-
Peso do frango ao final da terceira semana	g	-
Peso do frango ao final da quarta semana	g	-
Peso do frango ao final da quinta semana	g	-
Mortalidade ao final da primeira semana	%	-
Mortalidade ao final da segunda semana	%	-
Mortalidade ao final da terceira semana	%	-
Mortalidade ao final da quarta semana	%	-
Mortalidade ao final da quinta semana	%	-
Condenação parcial	%	-
Condenação total	%	-

## 2.5 Simulação de cenários

Para estimar o impacto da entrada nas variáveis de saída selecionadas para este estudo, diferentes cenários de produção foram simulados (Tabela 3). Para as variáveis numéricas (por exemplo, período de estocagem dos ovos, peso do frango, peso de pinto), a média foi obtida com base na série histórica disponível e foi considerado o valor padrão ou normal. Para simular valores “superiores” e “inferiores”, foi adicionado ou subtraído um desvio padrão, da respectiva média. Ao alterar os valores desses parâmetros, simulamos cenários de produção cujos resultados poderiam representar uma melhoria ou piora do desempenho.

Embora algumas variáveis categóricas de entrada não apareçam nos cenários produtivos descritos na tabela, todas variáveis foram incluídas nos seus respectivos modelos, como demonstrado no Material Suplementar (Tabela S2). A inclusão das variáveis em cada cenário foi baseada no grupo predominante para cada variável categórica. A inclusão de apenas um grupo por categoria foi

necessária porque os modelos de RNA não permitem projeções de dois ou mais grupos por variável categórica.

A unidade de medida foi definida como 1.000.000 de aves (pintos de um dia ou frangos de corte) por ciclo de produção para todos os cálculos de estimativa econômica. Os indicadores de referência utilizados neste estudo incluíram o rendimento médio de carne por carcaça (2,50 kg), preço médio pago ao produtor (R\$ 6,00/kg ou \$ 1,11/kg), preço médio do frango abatido (R\$ 7,08/kg ou \$ 1,31/kg), condenação parcial média de carcaça (20%) e preço do frango (R\$ 3,00/unidade ou \$ 0,74/unidade). Os valores em reais (R\$) foram obtidos do site Avisite<sup>(19)</sup> e referem-se a junho/2022. Todos os valores foram convertidos para dólares americanos (\$).

O software *NeuroShell Run-Time Server*<sup>(20)</sup> foi utilizado para prever os cenários de produção simulados, pois permite disparar os modelos de RNA gerados com o *NeuroShell Predictor*. O software *NeuroShell Fire*<sup>(21)</sup> foi utilizado para visualizar os valores preditos das variáveis de saída.

**Tabela 2.** Variáveis de entrada usadas para cada modelo de variável de saída (eclosão vendável, peso do frango ao final da quinta semana, condenação parcial e condenação total) gerados por redes neurais artificiais

Variáveis de entrada	Variáveis de saída <sup>1</sup>
Linhagem das aves	1, 2, 3, 4
Média de idade dos lotes de matrizes	1, 2, 3, 4
Tipo de ovo	1, 2, 3, 4
Peso do ovo	1
Período de estocagem dos ovos	1
Ovos trincados	1
Modelo de incubadora	1
Período de incubação	1
Número de lotes em cada nascedouro	1
Tempo no nascedouro	1
Contaminação nascedouro ( <i>Aspergillus</i> spp.)	1, 2, 3, 4
Contaminação nascedouro ( <i>Escherichia coli</i> )	1, 2, 3, 4
Contaminação nascedouro ( <i>Pseudomonas</i> spp.)	1, 2, 3, 4
Tipo de pinto	2, 3, 4
Peso de pinto	2, 3, 4
Sexo do lote	2, 3, 4
Peso do frango ao final da primeira semana	2, 3, 4
Peso do frango ao final da segunda semana	2, 3, 4
Peso do frango ao final da terceira semana	2, 3, 4
Peso do frango ao final da quarta semana	2, 3, 4
Peso do frango ao final da quinta semana	3, 4
Mortalidade ao final da primeira semana	3, 4
Mortalidade ao final da segunda semana	3, 4
Mortalidade ao final da terceira semana	3, 4
Mortalidade ao final da quarta semana	3, 4
Mortalidade ao final da quinta semana	3, 4

<sup>1</sup>Eclosão vendável (1); peso ao final da semana (2); condenação parcial (3) e condenação total (4).

**Tabela 3.** Cenários produtivos simulados para as variáveis de saída: “eclosão vendável”, “peso do frango ao final da quinta semana”, “condenação parcial” e “condenação total”

<b>Variável de saída: eclosão vendável</b>	
<b>Cenário</b>	<b>Variáveis de entrada manipuladas</b>
1	Linhagem A x ovo de ninho limpo x incubadora A
2	Linhagem A x ovo de ninho limpo x incubadora B
3	Linhagem A x ovo de ninho sujo x incubadora A
4	Linhagem A x ovo de ninho sujo x incubadora B
5	Linhagem B x ovo de ninho limpo x incubadora A
6	Linhagem B x ovo de ninho limpo x incubadora B
7	Linhagem B x ovo de ninho sujo x incubadora A
8	Linhagem B x ovo de ninho sujo x incubadora B
9	Período de estocagem dos ovos (média) <sup>1</sup> – 113 h
10	Período de estocagem dos ovos (inferior) <sup>1</sup> – 74 h
11	Período de estocagem dos ovos (superior) <sup>1</sup> – 152 h
<b>Variável de saída: peso do frango ao final da quinta semana</b>	
<b>Cenário</b>	<b>Variáveis de entrada manipuladas</b>
12	Linhagem A x lote de machos
13	Linhagem A x lote de fêmeas
14	Linhagem B x lote de machos
15	Linhagem B x lote de fêmeas
16	Peso do frango ao final da primeira semana (média) <sup>2</sup> – 184,84 g x lote de machos
17	Peso do frango ao final da primeira semana (superior) <sup>2</sup> – 203,22 g x lote de machos
18	Peso do frango ao final da primeira semana (inferior) <sup>2</sup> – 166,46 g x lote de machos
19	Peso do frango ao final da segunda semana (inferior) <sup>1</sup> – 426,97 g x lote de machos
20	Peso do frango ao final da terceira semana (inferior) <sup>1</sup> – 834,72 g x lote de machos
21	Peso do frango ao final da quarta semana (inferior) <sup>1</sup> – 1.340,72 g x lote de machos
22	Peso do frango ao final da primeira, segunda, e terceira semanas (inferior) <sup>1</sup> – 166,46g   426,97 g   834,72 g x lote de machos
<b>Variável de saída: condenação parcial</b>	
<b>Cenário</b>	<b>Variáveis de entrada manipuladas</b>
23	Linhagem A ou B x lote de machos
24	Linhagem A ou B x lote de fêmeas
25	Peso de pinto (média) <sup>3</sup> – 45,93 g x lote de machos
26	Peso de pinto (superior) <sup>3</sup> – 49 g x lote de machos
27	Peso de pinto (inferior) <sup>3</sup> – 42,85 g x lote de machos
28	Peso de pinto (média) <sup>3</sup> – 46,01 g x lote de fêmeas
29	Peso de pinto (superior) <sup>3</sup> – 49,61 g x lote de fêmeas
30	Peso de pinto (inferior) <sup>3</sup> – 42,41 g x lote de fêmeas
31	Peso de pinto (máximo) <sup>3</sup> – 50,2 g x lote de fêmeas
32	Peso de pinto (mínimo) <sup>3</sup> – 33,1 g x lote de fêmeas
33	Peso do frango ao final da segunda semana (média) <sup>4</sup> – 467,69 g x lote de machos
34	Peso do frango ao final da segunda semana (superior) <sup>4</sup> – 508,41 g x lote de machos
35	Peso do frango ao final da segunda semana (inferior) <sup>4</sup> – 426,97 g x lote de machos
36	Peso do frango ao final da terceira semana (média) <sup>1</sup> – 922,50 g x lote de machos
37	Peso do frango ao final da terceira semana (superior) <sup>1</sup> – 1.010,28 g x lote de machos
38	Peso do frango ao final da terceira semana (inferior) <sup>1</sup> – 834,72 g x lote de machos
39	Peso do frango ao final da segunda e terceira semanas (inferior) <sup>1</sup> – 508,41 g   1.010,28 g x lote de machos
<b>Variável de saída: condenação total</b>	
<b>Cenário</b>	<b>Variáveis de entrada manipuladas</b>
40	Linhagem A ou B x lote de machos
41	Linhagem A ou B x lote de fêmeas
42	Tipo de pinto (de matrizes < 37 semanas) x lote de machos
43	Tipo de pinto (de matrizes < 37 semanas) x lote de fêmeas
44	Tipo de pinto (de matrizes entre 38 a 49 semanas) x lote de machos
45	Tipo de pinto (de matrizes entre 38 a 49 semanas) x lote de fêmeas
46	Tipo de pinto (de matrizes >49 semanas) x lote de machos
47	Tipo de pinto (de matrizes >49 semanas) x lote de fêmeas
48	Mortalidade ao final da primeira, segunda e terceira semanas (baixa: 0,09%   0,62%   0,97%) <sup>5</sup>
49	Mortalidade ao final da primeira, segunda e terceira semanas (alta: 1,39%   1,70%   2,45%) <sup>5</sup>
50	Mortalidade ao final da primeira, segunda e terceira semanas (máxima: 2,16%   4,45%   4,06%) <sup>5</sup>
51	Peso do frango ao final da segunda semana (média) <sup>6</sup> – 467,69 g x lote de machos
52	Peso do frango ao final da segunda semana (superior) <sup>6</sup> – 508,41 g x lote de machos
53	Peso do frango ao final da segunda semana (inferior) <sup>6</sup> – 426,97 g x lote de machos

<sup>1</sup>Período de estocagem dos ovos, média: período médio de estocagem; inferior: período médio de estocagem menos um desvio padrão; superior: período médio de estocagem mais um desvio padrão. <sup>2</sup>Peso do frango ao final da quinta semana – média: média de peso; inferior: média de peso menos um desvio padrão; superior: média de peso mais um desvio padrão. <sup>3</sup>Peso de pinto – média: média de peso; inferior: média de peso menos um desvio padrão; superior: média de peso mais um desvio padrão. <sup>4</sup>Peso do frango ao final da segunda semana – média: média de peso; inferior: média de peso menos um desvio padrão; superior: média de peso mais um desvio padrão. <sup>5</sup>Mortalidade ao final da primeira, segunda e terceira semanas – baixa: média de mortalidade em cada semana menos um desvio padrão; alta: média de mortalidade mais um desvio padrão; máxima: máximo de mortalidade observada. <sup>6</sup>Peso do frango ao final da semana – média: peso médio; inferior: peso médio menos um desvio padrão; superior: peso médio mais um desvio padrão.

### 3. Resultados e discussão

A utilização de sistemas de monitoramento e ferramentas para análise de dados aumenta o lucro líquido de uma empresa<sup>(2)</sup>. A utilização de sistemas inteligentes para a tomada de decisão permite o máximo índice de desempenho e competitividade do mercado<sup>(13)</sup>. As

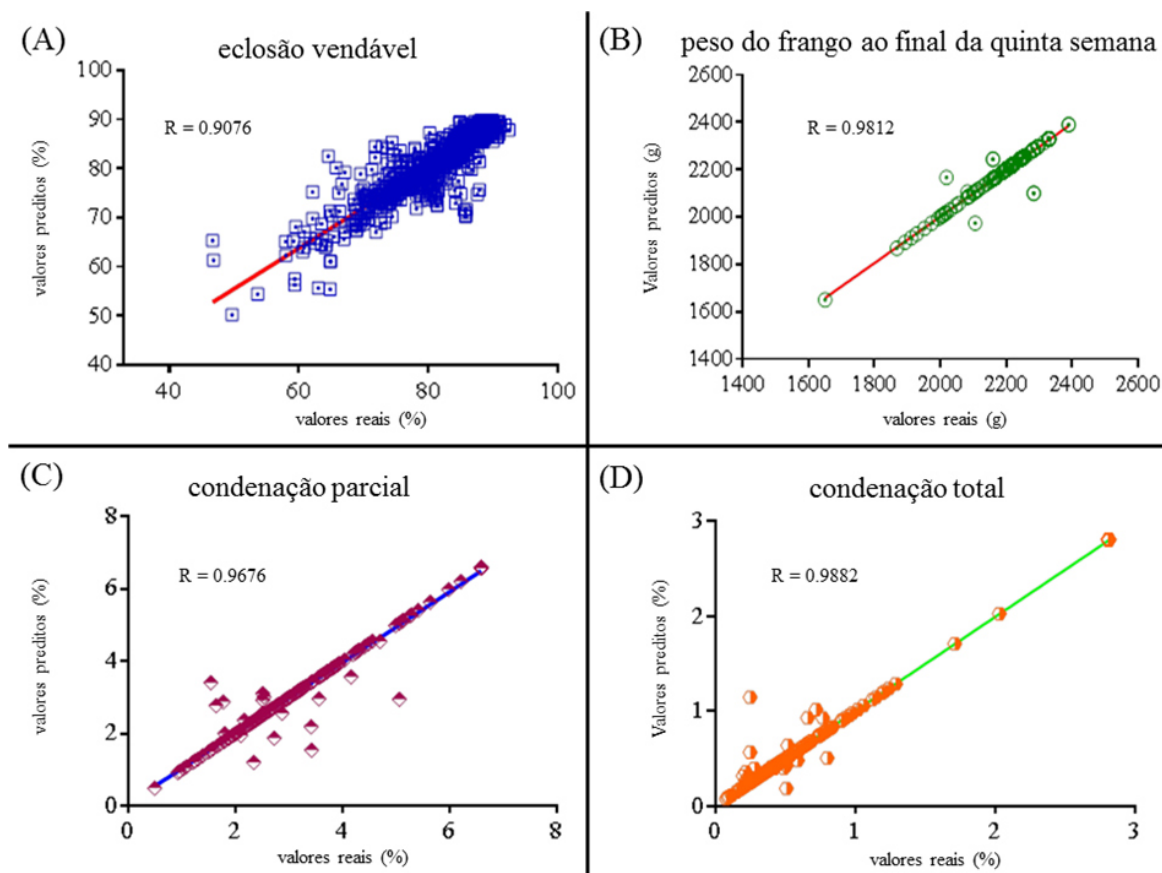
propriedades de cada modelo de RNA gerado, treinado e validado de acordo com as variáveis de saída de interesse estão listadas na Tabela 4.

A correlação entre os valores previstos e reais de cada uma das quatro variáveis de saída usando modelos RNA pode ser encontrada na Figura 1.

**Tabela 4.** Características matemáticas dos modelos gerados para as variáveis de saída: após treinamento e após validação

Resultados após treinamento					
Variável de saída	R <sup>2</sup>	R	E	EQM	REQM
eclosão vendável	0,8214	0,9066	1,9299	9,9593	3,1558
peso do frango ao final da quinta semana	0,9998	0,9999	0,1577	2,8144	1,6776
condenação parcial	0,9837	0,9918	0,0183	0,0171	0,1306
condenação total	0,9961	0,9880	0,0027	0,0004	0,0201
Resultados após validação					
Variável de saída	R <sup>2</sup>	R	E	EQM	REQM
eclosão vendável	0,8236	0,9066	1,8801	10,1390	3,1842
peso do frango ao final da quinta semana	0,9623	0,9999	3,5230	502,1338	22,4083
condenação parcial	0,9677	0,9918	0,0261	0,0323	0,1798
condenação total	0,9761	0,9880	0,0049	0,0027	0,0524

Legenda: Coeficiente de determinação múltipla (R<sup>2</sup>), coeficiente de correlação (R), erro quadrático médio (EQM) e raiz do erro quadrático médio (REQM).




**Figura 1.** Correlação entre os valores previstos e reais nos modelos de rede neural artificial (RNA), de acordo com cada variável de saída: eclosão vendável (A), peso ao final da quinta semana (B), condenação parcial (C) e total condenação (D).

Valores de  $R^2$  próximos a “1” indicam maior qualidade na validação da rede. Valores de  $R^2$  acima de 0,70 nos processos de treinamento da RNA indicam uma boa qualidade das redes para predição<sup>(7)</sup>. Após a validação, todas as variáveis de saída tiveram  $R^2$  acima de 0,70. “Peso ao final da quinta semana”, “condenação parcial” e “condenação total” apresentaram valores superiores a 0,96. Os valores obtidos indicaram que houve forte associação entre os dados previstos e os reais, demonstrando que os quatro modelos foram devidamente ajustados e, portanto, poderiam ser utilizados para simulações de cenários produtivos. Vale ressaltar que todas as variáveis também podem ser listadas como variáveis de saída. Essa escolha depende das necessidades da empresa<sup>(9,10)</sup>. As variáveis selecionadas como dados de “saída” neste estudo foram consideradas entre os resultados mais importantes a serem previstos de acordo com a empresa avícola avaliada. A importância relativa de cada variável de entrada nos modelos gerados para cada variável de saída é descrita no Material Suplementar (Tabela S2).

Avaliou-se a capacidade dos modelos de RNA em


predizer indicadores de produção e o potencial impacto econômico gerado a partir das relações das variáveis de um sistema de integração avícola. Assim, foram simulados cenários produtivos que combinavam diferentes variáveis. A elaboração dos modelos foi baseada em um banco de dados que incluiu uma série histórica de registros dos parâmetros produtivos da cadeia produtiva avícola. A Tabela S3 (Material Suplementar) resume os principais cenários simulados e seus impactos econômicos. Os resultados das variáveis de saída obtidos da simulação dos cenários de produção são descritos nas Figuras 2–5.

A criação de modelos matemáticos ajustados depende do registro correto dos dados, o que requer treinamento contínuo das pessoas envolvidas nesse processo. Ressalta-se também que os modelos criados a partir do banco de dados compartilhado pela empresa para esse estudo não podem ser utilizados em outros estabelecimentos, pois cada empresa possui um contexto produtivo único. Cada empresa deve construir seu próprio modelo de RNA, buscando aqueles que melhor se adaptam ao contexto<sup>(7)</sup>.




**Figura 2.** Valores de eclosão vendável (%) previstos a partir de cenários de produção simulados.

Legenda: (1) linhagem A × ovo de ninho limpo × incubadora A; (2) linhagem A × ovo de ninho limpo × incubadora B; (3) linhagem A × ovo de ninho sujo × incubadora A; (4) linhagem A × ovo de ninho sujo × incubadora B; (5) linhagem B × ovo de ninho limpo × incubadora A; (6) linhagem B × ovo de ninho limpo × incubadora B; (7) linhagem B × ovo de ninho sujo × incubadora A; (8) linhagem B × ovo de ninho sujo × incubadora B; (9) período de estocagem dos ovos (média: 113 h); (10) período de estocagem dos ovos (inferior: 74 h); (11) período de estocagem dos ovos (superior: 152 h).



**Figura 3.** Peso do frango no final da quinta semana (g) previsto a partir de cenários de produção simulados.


Legenda: (12) linhagem A × lote de machos; (13) linhagem A × lote de fêmeas (14) linhagem B × lote de machos; (15) linhagem B × lote de fêmeas; (16) peso do frango ao final da primeira semana (média: 184,84 g) × lote de machos; (17) peso do frango ao final da primeira semana (superior: 203,22 g) × lote de machos; (18) peso do frango ao final da primeira semana (inferior: 166,46 g) × lote de machos; (19) peso do frango ao final da segunda semana (inferior: 426,97 g) × lote de machos; (20) peso do frango ao final da terceira semana (inferior: 834,72 g) × lote de machos; (21) peso do frango ao final da quarta semana (inferior: 1.340,72 g) × lote de machos; (22) peso do frango ao final das semanas 1, 2, e 3 (inferior: 166,46 g, 426,97 g, e, 834,72 g, respectivamente) × lote de machos.



**Figura 4.** Condenação parcial (%) prevista a partir de cenários de produção simulados.

Legenda: (23) linhagem A ou linhagem B × lote de machos; (24) linhagem A ou linhagem B × lote de fêmeas; (25) peso de pinto (média: 45,93 g) × lote de machos; (26) peso de pinto (superior: 49 g) × lote de machos; (27) peso de pinto (inferior: 42,85 g) × lote de machos; (28) peso de pinto (média: 46,01 g) × lote de fêmeas; (29) peso de pinto (superior: 49,61 g) × lote de fêmeas; (30) peso de pinto (inferior: 42,41 g) × lote de fêmeas; (31) peso de pinto (máximo: 50,2 g) × lote de fêmeas; (32) peso de pinto (mínimo: 33,1 g) × lote de fêmeas; (33) peso do frango ao final da segunda semana (média: 467,69 g) × lote de machos; (34) peso do frango ao final da segunda semana (superior: 508,41 g) × lote de machos; (35) peso do frango ao final da segunda semana (inferior: 426,97 g) × lote de machos; (36) peso do frango ao final da terceira semana (média: 922,50 g) × lote de machos; (37) peso do frango ao final da terceira semana (superior: 1.010,28 g) × lote de machos; (38) peso do frango ao final da terceira semana (inferior: 834,72 g) × lote de machos; (39) peso do frango ao final da segunda e terceira semanas (inferior: 508,41 g e 1.010,28 g, respectivamente) × lote de machos.





**Figura 5.** Condenação total (%) prevista a partir de cenários de produção simulados.

Legenda: (40) linhagem A ou linhagem B × lote de machos; (41) linhagem A ou linhagem B × lote de fêmeas; (42) tipo de pinto (de matrizes até 37 semanas) × lote de machos; (43) tipo de pinto (de matrizes até 37 semanas) × lote de fêmeas; (44) tipo de pinto (de matrizes entre 38 a 49 semanas) × lote de machos; (45) tipo de pinto (de matrizes entre 38 a 49 semanas) × lote de fêmeas; (46) tipo de pinto (de matrizes com mais de 49 semanas) × lote de machos; (47) tipo de pinto (de matrizes com mais de 49 semanas) × lote de fêmeas; (48) mortalidade ao final da primeira, segunda e terceira semanas (baixa: 0,09%, 0,62%, e 0,97%, respectivamente); (49) mortalidade ao final da primeira, segunda e terceira semanas (alta: 1,39%, 1,70%, e 2,45%, respectivamente); (50) mortalidade ao final da primeira, segunda e terceira semanas (máxima: 2,16%, 4,45%, e 4,06%, respectivamente); (51) peso do frango ao final da segunda semana (média: 467,69 g) × lote de machos; (52) peso do frango ao final da segunda semana (superior: 508,41 g) × lote de machos; (53) peso do frango ao final da segunda semana (inferior: 426,97 g) × lote de machos.

O treinamento dos quatro modelos nesse estudo foi realizado usando um método genético. A principal limitação desse método é que as projeções só podem ser feitas a partir de valores que estejam dentro do intervalo entre o máximo e o mínimo de cada variável que constitui a série histórica em análise.

### 3.1 Variável de saída: eclosão vendável (cenários 1 a 11)

De um total de 1.000.000 de ovos incubados, cada aumento de 0,1% na taxa de eclosão vendável significa um acréscimo de 1.000 pintos para comercialização, ou R\$ 740,00 de receita. Assim, todos os ganhos e perdas resultam em um grande impacto financeiro.

*Influência da incubadora (cenários 1 a 8).* As taxas de eclosão vendáveis previstas demonstraram que a incubadora A teve um desempenho melhor do que a incubadora B. A diferença nas taxas de eclosão vendáveis entre as incubadoras foi de 4,9% quando a linhagem A e ovos de ninho limpos são incubados (cenários 1 e 2). Portanto, a diferença de receita entre as incubadoras foi de aproximadamente R\$ 36.260,00, considerando a incubação de um milhão de ovos nas mesmas condições.

A diferença de eclosão observada na incubação da linhagem B e dos ninhos limpos (cenários 5 e 6) foi de 1,91%, o que pode representar um acréscimo de aproximadamente \$ 14.134,00 quando se utiliza a incubadora A. Foi verificado desempenho superior da incubadora A quando ovos de ninho sujo da linhagem B são incubados (cenários 7 e 8), com uma diferença de 20,45% entre as taxas de eclosão.

*Influência do período de estocagem dos ovos (cenários 9 a 11).* Ao reduzir o período de estocagem dos ovos embrionados de 113 h (cenário 9) para 74 h (cenário 10), houve um ganho de 0,9% na taxa de eclosão vendável. Esse resultado projetado pode servir de argumento ao gerente do incubatório para futuras mudanças nos procedimentos, visando reduzir o tempo de espera dos ovos embrionados na sala de ovos. Os embriões das linhagens A e B tiveram trajetórias de crescimento diferenciadas devido a diferenças nos parâmetros fisiológicos. A linhagem A tem um desenvolvimento mais rápido nos primeiros 4-5 dias, mas a linhagem B se desenvolve mais rapidamente na segunda semana de incubação. Assim, as condições de incubação podem ser melhoradas para cada linhagem<sup>(23)</sup>.

### 3.2 Variável de saída: peso do frango ao final da quinta semana (cenários 12 a 22)

*Influência da linhagem (cenários 12 a 15).* As previsões de peso dos frangos ao final da quinta semana demonstraram que as linhagens apresentaram diferenças de desempenho. Os frangos machos da linhagem A pesaram aproximadamente 4,88% (98 g) a mais do que os machos da linhagem B. Uma diferença de 98 g pode representar um aumento de US\$ 0,13 por frango abatido. O rendimento de um ciclo de produção com um milhão de aves, todas machos, pode aumentar em R\$ 130.000,00. Algumas empresas avícolas brasileiras abatem mais de um milhão de aves por dia. Assim, o impacto econômico estimado é evidente e pode justificar a política adotada pela empresa para o uso predominante (83,11%) da linhagem A. O sexo dos frangos de corte é um fator que pode ter efeitos significativos nos parâmetros de produção, sendo que os machos costumam apresentar maiores índices de produção do que as fêmeas<sup>(1)</sup>. Não houve diferença de desempenho ao comparar lotes de fêmeas entre as linhagens. Apesar de estudos anteriores já terem demonstrado que frangos de corte da linhagem A costumam apresentar peso superior aos da linhagem B<sup>(24,25)</sup>, este é o primeiro relato que descreve as possíveis diferenças de renda em empresas brasileiras.

*Influência do peso dos frangos ao final das semanas 1, 2, 3 e 4 (cenários 16 a 22).* Estudos anteriores demonstram que os frangos de corte mais pesados ao abate geralmente apresentam os maiores pesos iniciais na primeira semana. Assim, o peso inicial do pinto é descrito como um fator determinante no desempenho final do frango de corte. Além disso, durante esse período, aproximadamente 80% da energia do pinto é utilizada para o crescimento<sup>(26)</sup>. No entanto, nesse estudo, os modelos de RNA demonstraram que o peso do frango no final da primeira semana (cenários 16–18) pode não ter uma influência significativa no peso do frango no final da quinta semana para essa empresa.

É possível que pintos com peso reduzido na primeira semana tenham tempo para superar as perdas e apresentem um ganho de peso compensatório nas semanas 2, 3 e 4, quando condições favoráveis de manejo e nutrição estiverem disponíveis. É provável que haja um limite mínimo de peso para se evitar variações ao final da semana 5<sup>(27)</sup>. Assim, tem sido sugerido que a seleção genética deveria focar no aumento da produção de ovos ao invés do peso do ovo<sup>(28)</sup>. Frangos de corte que atingirem o final das semanas 2, 3 ou 4 (cenários 19 a 22) com peso abaixo de seu potencial médio terão peso menor no final da semana 5, indicando que não há tempo suficiente para se recuperar o peso após a segunda semana. Por exemplo, no cenário 20, o peso do frango ao final da semana 3 (834,72 g) foi menor do que o esperado

pela empresa (922,5 g). O potencial de perda de renda para o produtor neste cenário é de aproximadamente R\$ 100.000,00. Essas previsões são importantes para se evitar possíveis impactos negativos no peso final dos frangos de corte, adotando-se medidas para evitar a ocorrência de tais cenários.

### 3.3 Variável de saída: condenação parcial (cenários 23 to 39)

*Influência do sexo do lote (cenário 23 ao 32).* Os resultados demonstram que lotes de fêmeas, independente da linhagem, apresentam maior taxa de condenação parcial de carcaças do que lotes de machos. Essa diferença, calculada em 0,25% (cenários 23 e 24), representa 2.500 carcaças e 1.250 kg de carne de frango descartados em um milhão de frangos de corte abatidos. A perda econômica final é estimada em aproximadamente \$ 1.637,00 por milhão de frangos de corte abatidos. Para uma empresa que abate um milhão de aves por dia, após um mês, o valor pode chegar a R\$ 49.125,00, considerando 50% dos plantéis de fêmeas. Entretanto, deve-se ressaltar que ainda não existem dados na literatura que expliquem a diferença de condenação de carcaça associada ao sexo do lote.

*Peso de pinto (cenários 25 a 32).* Não foi observado efeito do peso de pinto de um dia sobre a taxa de condenação parcial. Estudos anteriores demonstraram que o crescimento diário aumentado em frangos de corte está associado a taxas de condenação mais altas<sup>(1)</sup>.

*Peso do frango (cenários 33 a 39).* Embora o peso de pinto não tenha influenciado nas taxas de condenação, os resultados desse estudo demonstraram que um maior peso ao final das semanas 2 e 3 resultou em menor taxa de condenação parcial das carcaças. Assim, a adoção de estratégias de criação e manejo que favoreçam o maior ganho de peso nessas semanas pode garantir grandes contribuições no faturamento da empresa.

### 3.4 Variável de saída: condenação total (cenários 40 a 53)

*Influência do sexo do lote (cenários 40 a 47).* Embora os lotes de fêmeas tenham apresentado uma taxa de condenação parcial maior do que os lotes de machos, isso não foi observado na taxa de condenação total.

*Influência do tipo de pinto (cenários 42 a 47).* O modelo de predição demonstrou que o tipo de pinto (idade da matriz) não influenciou nas taxas de condenação total, independentemente do sexo do lote. Esses achados indicam que os efeitos do sexo e do peso do frango nas primeiras semanas na condenação parcial não são lineares e podem não ser explicados por uma associação direta.

*Influência da mortalidade ao final das semanas 1, 2, e 3 (cenários 48 a 50).* O efeito da mortalidade acumulada (baixa ou alta) na condenação total das

carcaças também foi avaliado. Ao reduzir as taxas de mortalidade nas semanas 1, 2 e 3 em pelo menos um desvio padrão, houve uma diminuição no valor previsto da taxa total de condenação de carcaças. A diferença entre a taxa média esperada e a alta mortalidade (cenário 48) foi de aproximadamente -0,0795%. Em um ciclo de produção com um milhão de aves, essa diferença representa uma redução na condenação de pelo menos 795 carcaças, aproximadamente R\$ 2.603,00. A projeção com a ocorrência de mortalidade combinada máxima nas três primeiras semanas (cenário 50) resultou em um aumento de 0,9405% na taxa de condenação total, o que significa uma perda de aproximadamente \$ 30.785,00 para cada um milhão de aves abatidas. As taxas de mortalidade simuladas nesse estudo (2–5%) podem ser atribuídas a vários fatores. A primeira semana é um período sensível em que muitos sistemas e órgãos das galinhas ainda estão imaturos. Características individuais dependentes, como idade da matriz, sexo do pinto e linhagem, bem como fatores externos, incluindo tipo de aviário, estocagem de ovos e estação do ano, estão relacionados à mortalidade na primeira semana<sup>(29)</sup>. Altas taxas de mortalidade nas últimas semanas podem ser uma indicação de problemas de manejo ou de doenças que são comuns na avicultura. Frangos de corte que sobrevivem nestas condições podem ter seu desempenho produtivo comprometido, o que leva a uma maior desuniformidade nos lotes. A uniformidade anormal do lote resulta em maior taxa de condenações<sup>(1)</sup>, devido à evisceração automática no abatedouro, que pode causar ruptura de vísceras e extravasamento do conteúdo intestinal<sup>(30)</sup>. Assim, nossos achados suportam a ideia de que lotes com maiores taxas de mortalidade podem ter uma maior taxa de condenação parcial e total de carcaça.

*Influência do peso do frango ao final da segunda semana (cenários 51 a 53).* Em relação ao efeito do peso do frango ao final da segunda semana sobre a taxa de condenação total, observou-se que tanto a redução quanto o aumento do peso do frango podem resultar na diminuição da taxa de condenação. Nesses casos, os resultados previstos são difíceis de entender porque carecem de uma explicação lógica (relação linear). Por outro lado, os modelos preditivos possuem grande capacidade assertiva, conforme verificado na etapa de validação.

#### 4. Conclusão

Os modelos de RNA gerados nesse estudo foram adequados para simulações de cenários de produção e possibilitaram a previsão de parâmetros produtivos importantes para a cadeia produtiva avícola. Os resultados obtidos nesse estudo demonstram que as empresas podem utilizar modelos preditivos para adotar estratégias que minimizem o impacto negativo de determinados cenários. A empresa também pode

gerenciar melhor seus recursos porque os efeitos de diferentes cenários podem ser previstos pelos modelos.

#### Material suplementar

Disponível on-line em : Link será colocado após a publicação.

#### Declaração de conflito de interesse

Os autores não possuem interesses conflitantes.

#### Contribuições dos autores

*Conceituação:* C.T.P. Salle, H.L.S. Moraes, V.P. do Nascimento e E. Camilotti. *Curadoria de dados:* E. Camilotti. *Análise formal:* E. Camilotti. *Investigação:* E. Camilotti, T.Q. Furian, K.A. Borges e D.T. da Rocha. *Metodologia:* E. Camilotti e D.T. da Rocha. *Administração do projeto:* C.T.P. Salle, H.L.S. Moraes e V.P. do Nascimento. *Software:* C.T.P. Salle, E. Camilotti e D.T. da Rocha. *Supervisão:* C.T.P. Salle, H.L.S. Moraes e V.P. do Nascimento. *Validação:* E. Camilotti, T.Q. Furian e K.A. Borges. *Redação (rascunho original):* E. Camilotti, K.A. Borges e T.Q. Furian. *Redação (revisão & edição):* K.A. Borges e T.Q. Furian.

#### Referências

1. Van Limbergen T, Sarrazin S, Chantziaras I, Dewulf J, Ducatelle R, Kyriazakis I, McMullin P, Méndez J, Niemi JK, Papasolomontos S, Szeleszczuk P, Van Erum J, Maes D. Risk factors for poor health and performance in European broiler production systems. *BMC Vet Res* 2020;16:287. <https://doi.org/10.1186/s12917-020-02484-3>
2. Ramírez-Morales I, Fernández-Blanco E, Rivero D, Pazos A. Automated early detection of drops in commercial egg production using neural networks. *Brit Poult Sci* 2017; 58:739-747. <https://doi.org/10.1080/00071668.2017.1379051>
3. Tedeschi LO. Mathematical modeling in ruminant nutrition: approaches and paradigms, extant models, and thoughts for upcoming predictive analytics. *J Anim Sci* 2019; 97:1921-1944. <https://doi.org/10.1093/jas/skz092>
4. Vanneschi L., Castelli M. Multilayer perceptrons. In: Ranganathan S., Nakai K., Schonbach C. *Encyclopedia of Bioinformatics and Computational Biology*. Amsterdam: Elsevier; 2018. p. 612-620.
5. Abiodun OI, Jantan A, Omolara AE, Dada KV, Mohamed NAE, Arshad H. State-of-the-art in artificial neural network applications: A survey. *Heliyon* 2018; 4(11):e00938. <https://doi.org/10.1016/j.heliyon.2018.e00938>
6. Safari-Aliqiarloo A, Faghieh-Mohammadi F, Zare M, Seidavi A, Laudadio V, Selvaggi M, Tufarelli V. Artificial neural network and non-linear logistic regression models to fit the egg production curve in commercial-type broiler breeders. *Eur Poult Sci* 2017; 81. <http://doi.org/10.1399/eps.2017.212>
7. Salle CTP, Guahyba AS, Wald VB, Silva AB, Salle FO, Nascimento VP. Use of artificial neural networks to estimate production parameters of broiler breeders in the breeding phase. *Brit Poult Sci* 2003; 44: 211-217. <https://doi.org/10.1080/0007166031000088361>
8. Salle CTP, Spohr A, Furian TQ, Borges KA, Rocha DT, Moraes HLS, Nascimento VP. 2018. *Inteligência Artificial: o futuro da produção avícola*. Avicultura Industrial. Nº 7, ano 109, ed.

1279, p. 38-42

9. Almeida LGB, Oliveira EB, Furian TQ, Borges KA, Rocha DT, Salle CTP, Moraes HLS. Artificial neural networks on eggs production data management. *Acta Scient Vet* 2020; 48:1-7. <https://doi.org/10.22456/1679-9216.101462>

10. Oliveira EB, Almeida LGB, Rocha DT, Furian TQ, Borges KA, Moraes HLS, Nascimento VP, Salle CTP. Artificial neural networks to predict egg production traits in commercial laying breeder hens. *Braz J Poult Sci* 2022; 24(4):1-10. <http://dx.doi.org/10.1590/1806-9061-2021-1578>

11. Carvalho D, Moraes LB, Chitolina GZ, Herpich JI, Osório FS, Fallavena LCB, Moraes HLS, Salle CTP. Evaluation of thymic lymphocyte loss of broiler using Digital Analysis of the Lymphoid Depletion System (ADDL). *Pesq Vet Bras* 2016; 36(07):652-656. <https://doi.org/10.1590/S0100-736X2016000700016>

12. Moraes LB, Osório FS, Salle FO, Souza GF, Moraes HLS, Fallavena LCB, Santos LR, Salle CTP. Evaluation of follicular lymphoid depletion in the Bursa of Fabricius: an alternative methodology using digital image analysis and artificial neural networks. *Pesq Vet Bras* 2010; 30(4):340-344. <https://doi.org/10.1590/S0100-736X2010000400010>

13. Abreu LHP, Yanagi Junior T, Yamid MB, Hernández-Julio YF, Ferraz PFP. Artificial neural networks for prediction of physiological and productive variables of broilers. *Eng Agric* 2020; 40(1):1-9. <https://doi.org/10.1590/1809-4430-Eng.Agric.v40n1p1-9/2020>

14. Lourençoni D, Junior TY, Abreu PG, Campos AT, Yanagi SNM. Productive responses from broiler chickens raised in different commercial production systems – part I: fuzzy modeling. *Eng Agric* 2019; 39:1-10. <https://doi.org/10.1590/1809-4430-Eng.Agric.v39n1p1-10/2019>

15. van der Klein SAS, More-Bayona JA, Barreda DR, Romero LF, Zuidhof MJ. Comparison of mathematical and comparative slaughter methodologies for determination of heat production and energy retention in broilers. *Poult Sci* 2020; 99:3237-3250. <https://doi.org/10.1016/j.psj.2020.02.005>

16. You J, Lou E, Afrouziyeh M, Zukiwsky NM, Zuidhof MJ. Using an artificial neural network to predict the probability of oviposition events of precision-fed broiler breeder hens. *Poultry Science*, 2021; 100(8):101187. <https://doi.org/10.1016/j.psj.2021.101187>

17. Mendes AS, Gudoski DC, Cargnelutti AF, Silva EJ, Carvalho EH, Morello GM. Factors that impact the financial performance of broiler production in southern states of Paraná. *Braz J Poult Sci* 2014; 16(1):113-120. <https://doi.org/10.1590/S1516-635X2014000100016>

18. NeuroShell Predictor. Ward Systems Group, version 4.0 TM. Frederick, MD, USA. (<http://www.wardsystems.com/predictor.asp>)

19. Avisite. Estatísticas e preços. Campinas: Mundo Agro Editora Ltda. Available from: <https://www.avisite.com.br/estatisticas-precos> (accessed: July 20, 2022)

20. NeuroShell Run-Time Server. Ward Systems Group, version 4.0 TM. Frederick, MD, USA. (<http://www.wardsystems.com/predictor.asp>)

21. NeuroShell Run-Time Server. Ward Systems Group, version 4.0 TM. Frederick, MD, USA. (<http://www.wardsystems.com/rtserver.asp>)

22. NeuroShell Fire. Ward Systems Group, version 4.0 TM. Frederick, MD, USA. (<http://www.wardsystems.com/rtserver.asp>)

23. Tona K, Onagbesan OM, Kamers B, Everaert N, Bruggeman V, Decuypere E. Comparison of Cobb and Ross strains in embryo physiology and chick juvenile growth. *Poult Sci* 2010; 89(8):1677-1683. <https://doi.org/10.3382/ps.2009-00386>

24. Arruda JNT, Mendes AS, Guirro ECBP, Schneider M, Sikorski RR, Sausen L, Dias ER, Bonamigo DV. Live performance, carcass yield, and welfare of broilers of different genetic strains reared at different housing densities. *Braz J Poult Sci* 2016; 18(1):141-152. <https://doi.org/10.1590/18069061-2015-0092>

25. Khalid N, Ali MM, Ali Z, Amin Y, Ayaz M. Comparative productive performance of two broiler strains in open housing system. *Advancem Life Sci* 2021; 8(2):124-127.

26. Mendes AS, Paixão SJ, Restelatto R, Refatti R, Possenti JC, Moura DJ, Morello GMZ, Carvalho TMR. Effects of initial body weight and litter material on broiler production. *Braz J Poult Sci* 2011; 13(3):165-170. <https://doi.org/10.1590/S1516-635X2011000300001>

27. Michalczuk M, Stepinska M, Lukasiewicz M. Effect of the initial body weight of Ross 308 chicken broilers on the rate of growth. *Animal Science* 2011; 49: 121-125. <https://doi.org/10.1590/S1516-635X2011000300001>

28. Jiang RS, Yang N. Effect of day-old body weight on subsequent growth, carcass performances and levels of growth-related hormones in quality meat-type chicken. *European Poultry Science* 2007; 71(2):93-96.

29. Yerpes M, Llonch P, Manteca X. Factors associated with cumulative first-week mortality in broiler chicks. *Animals* 2020; 10(2):310. <https://doi.org/10.3390/ani10020310>

30. Santana AP, Murata LS, Freitas CG, Delphino MK, Pimentel CM. Causes of condemnation of carcasses from poultry in slaughterhouses located in State of Goiás, Brazil. *Cienc Rur* 2008; 38(9):2587-2592. <https://doi.org/10.1590/S0103-84782008005000002>