

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE DE VETERINÁRIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS VETERINÁRIAS

**GERENCIAMENTO DE ÍNDICADORES DE PRODUÇÃO EM LOTES DE
MATRIZES DE POSTURA COMERCIAL
UTILIZANDO REDES NEURAS ARTIFICIAIS**

Dissertação de Mestrado

Autor: Eder Barbosa Oliveira

Dissertação apresentada como requisito
parcial para obtenção do grau de Mestre em
Ciências Veterinárias na especialidade de
Sanidade Avícola.

Orientador: Carlos Tadeu Pippi Salle

PORTO ALEGRE

2020

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE DE VETERINÁRIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS VETERINÁRIAS

**GERENCIAMENTO DE ÍNDICADORES DE PRODUÇÃO EM LOTES DE
MATRIZES DE POSTURA COMERCIAL
ATRAVÉS DO USO DE REDES NEURAS ARTIFICIAIS**

Autor: Eder Barbosa Oliveira

Dissertação apresentada como requisito parcial para a obtenção do grau de Mestre em Ciência Veterinária na Área de Sanidade Avícola no Programa de Pós-Graduação em Ciências Veterinárias da UFRGS.

Orientador: Carlos Tadeu Pippi Salle

PORTO ALEGRE

2020

CIP - Catalogação na Publicação

Barbosa Oliveira, Eder
Gerenciamento de indicadores de produção em lotes
de matrizes de postura comercial utilizando redes
neurais artificiais / Eder Barbosa Oliveira. -- 2020.
50 f.
Orientador: Carlos Tadeu Pippi Salle.

Dissertação (Mestrado) -- Universidade Federal do
Rio Grande do Sul, Faculdade de Veterinária, Programa
de Pós-Graduação em Ciências Veterinárias, Porto
Alegre, BR-RS, 2020.

1. Redes Neurais Artificiais. 2. Matrizes de
Aptidão Postura Comercial. 3. Gerenciamento de
Indicadores de Produção. I. Tadeu Pippi Salle, Carlos,
orient. II. Título.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da UFRGS com os
dados fornecidos pelo(a) autor(a).

Eder Barbosa Oliveira

**GERENCIAMENTO DE ÍNDICADORES DE PRODUÇÃO EM LOTES DE
MATRIZES DE POSTURA COMERCIAL
ATRAVÉS DO USO DE REDES NEURAIAS ARTIFICIAIS**

Aprovada em 13 de fevereiro de 2020.

Prof. Dr. Carlos Tadeu Pippi Salle
Orientador e Presidente da Comissão

Prof. Dr. Hamilton Luiz de Souza Moraes
Membro da Comissão

Prof^a. Dr^a. Daniela Tonini da Rocha
Membro da Comissão

Dr. Erich Helfer Carvalho
Membro da Comissão

AGRADECIMENTOS

Em primeiro lugar agradeço a Deus pela vida, pelas oportunidades, pela força de querer continuar e por concluir mais uma etapa da minha vida, à minha esposa Eula A. Rodrigues Oliveira que me apoiou em todos os momentos; meu filho Samuel que veio para enriquecer mais a minha vida; minha mãe Neiva Barbosa Oliveira pelas orações e confiança, muito obrigado por tudo, amo muito vocês!

Aos meus irmãos, Giovane Barbosa Oliveira e Ediane Barbosa Oliveira, que ao longo de minha trajetória deram-me força para continuar, muito obrigado pelo amor, carinho e por estarem sempre ao meu lado.

Ao meu orientador, Dr. Carlos Tadeu Pippi Salle, obrigado por atender-me com atenção todas as vezes que solicitei, respondendo-me sempre com muita rapidez.

Aos diretores Gauben Peruzzo e Henrique Roman pela confiança depositada.

À empresa que forneceu os dados para esse trabalho e a todos os funcionários que, de alguma forma, ensinaram-me algo, não somente aprendizado técnico, como também de vida.

E a todas as pessoas que estiveram presentes no decorrer da minha história, seja como amigos, colegas, professores, alguns citados acima e os demais que estarão sempre presentes no pensamento e no coração. Vocês me ajudaram a realizar mais um grande sonho. Serei eternamente grato a vocês!

RESUMO

Este trabalho teve por objetivo utilizar redes neurais artificiais para prever indicadores de produção dos lotes de matrizes de postura comercial em uma empresa matrizeira de aptidão postura comercial. Foram utilizados dados de 2007 a 2014, usando 51 lotes das linhagens Isa Brown e Bovans Withe totalizando 405.511 aves avaliadas. A empresa participante do experimento forneceu um banco de dados com informações de vários lotes pelo período de 7 anos. Para a construção das redes neurais artificiais foram utilizados os programas computacionais NeuroShell®Classifier e NeuroShell® Predictor, desenvolvidos pela Ward Systems Group. O programa identificou as variáveis escolhidas como “entradas” para cálculo do modelo preditivo e variável de “saída” aquela a ser predita. Neste trabalho foram utilizados 2.370 linhas para o treinamento, outras 593 serviram como testes para validação das previsões, para obtenção dos resultados as redes neurais artificiais passaram por duas fases, na primeira foram apresentados o treinamento para as redes utilizando -se todas as variáveis de entrada que antecederam as variáveis de saída de cada rede. A segunda fase destinou-se à validação dos modelos com todas as variáveis de entrada que antecederam as variáveis de saída como: ovos produzidos semanal, consumo real de ração semanal, ovo/ave/alojada, ovo comercial semanal, ovo incubável semanal, peso de ovo real, produção de ovos real e viabilidade. Em todos esses oito modelos as redes neurais artificiais foram bem ajustadas, apresentando um Coeficiente de Determinação Múltipla (R^2) próximo de um (1), salientando que R^2 quanto mais se aproximar de 1 maior precisão. De acordo com os dados apresentados pelas RNAs conclui se que foi possível prever as informações alocadas dos lotes de matrizes de aptidão postura comercial, gerando previsões úteis nas oito redes apresentadas além de apontar falhas nos dados da planilha de produção.

Palavras-chave: Redes Neurais Artificiais, Matrizes de Aptidão Postura Comercial, Gerenciamento de Indicadores de Produção.

ABSTRACT

The objective of this study was to use artificial neural networks to predict zootechnical indexes of layer parent stocks' flocks in a genetic company. Data from 2007 to 2014 were used considering about 51 flocks of Isa Brown and Bovans White lineages, totaling 405.511 birds evaluated. The company which participated in the experiment provided a database with information on several flocks over a period of 7 years. For the construction of artificial neural networks were used the computer programs NeuroShell®Classifier and NeuroShell® Predictor, developed by the Ward Systems Group. The program identified the variables chosen as "inputs" to calculate the predictive model and the "output" variable to be predicted. In this study 2.370 lines were used for training, others 593 served as tests to validate predictions. To obtain the results, the artificial neural networks went through two phases. In the first one, the training for the networks was presented using all the input variables that preceded the output variables of each network. The second phase was focused on validating the models with all input variables that preceded the output variables such as viability, fertile eggs production, utilization, egg / bird / housed and feed intake. In all of these models the artificial neural networks were well adjusted, presenting a high Multiple Determination Coefficient (R^2), emphasizing that R^2 the closer it comes to 1, higher is the precision. According to the data presented by the RNAs, it is concluded that it was possible to predict the information allocated from the commercial posture aptitude matrices, generating useful predictions in the eight networks presented in addition to pointing out flaws in the data of the production.

Keywords: *Artificial Neural Networks, Layer Parent Stock, Production Indicator Management.*

Lista de tabelas

Tabela 1 - Características do treinamento modelo de rede neural para predição da saída de ovos produzido semanal.....	19
Tabela 2 - Importância relativas das variáveis semanal	19
Tabela 3 - Validação do modelo de redes neurais para predição de ovos produzidos semanalmente	20
Tabela 4 - Características do treinamento do modelo de rede neural para predição da saída de consumo real de ração semanal	21
Tabela 5 - Contribuições, ou importância relativas, de cada uma das variáveis de entrada para saída de consumo real de ração semanalmente	22
Tabela 6 - Validação do modelo de redes neurais para predição de consumo real de ração semanal	22
Tabela 7 - Características do treinamento do modelo de rede neural para predição da saída de Ovo/Ave/Alojada.....	23
Tabela 8 - Importância relativa das variáveis de entrada e saída de Ovo/Ave/Alojada	24
Tabela 9 - Validação de redes neurais para predição de Ovo/Ave/Alojada	24
Tabela 10 - Características do treinamento do modelo de rede neural para predição da saída de Ovos Comercial Semanal	25
Tabela 11 - Demonstração das importâncias relativas de cada variável de entrada para saída de Ovos Comercial Semanal	26
Tabela 12 - Validação do modelo de redes neurais para predição de Ovos Comercial Semanal.	26
Tabela 13 - Características do treinamento do modelo de rede neural para predição da saída de Ovos Incubável Semanal	27
Tabela 14 - Importâncias relativas das variáveis de entrada para saída de Ovos Incubáveis Semanal	30
Tabela 15 - Validação do modelo de redes neurais para predição de Ovos Incubável Semanal..	30
Tabela 16 - Características do treinamento do modelo de rede neural para predição da saída de Peso de Ovo Real.....	29
Tabela 17 - Demonstração das importâncias relativas de cada uma variável de entrada para saída de Peso de Ovo Real.....	30
Tabela 18 - Validação do modelo de redes neurais para predição de Peso de Ovo Real	30

Tabela 19 - Características do treinamento do modelo de rede neural para predição da saída de Produção do Ovos Real	31
Tabela 20 - Contribuições ou importâncias relativas de cada uma das variáveis de entrada para saída de Produção de Ovos Real.....	32
Tabela 21 - Validação do modelo de redes neurais para predição de Produção de Ovos Real	34
Tabela 22 - Características do treinamento do modelo de rede neural para predição da saída de Viabilidade	33
Tabela 23 - Contribuições ou importâncias relativas de cada uma das variáveis de entrada para Viabilidade	34
Tabela 24 - Validação do modelo de redes neurais para predição de Viabilidade	34

LISTA DE FIGURAS

Figura 1 - Exemplo esquemático da arquitetura de rede neural	20
Figura 2 - Contribuições ou importâncias relativas, de cada uma das variáveis de entrada para Ovos Produzidos Semanal	22
Figura 3 - Valores reais (X) versus valores preditos (Y) de Ovos Produzidos Semanal dos 51 lotes de matrizes aptidão leve.....	23
Figura 4 - Contribuições ou importâncias relativas, de cada uma das variáveis de entrada para Consumo Real de Ração Semanal.....	24
Figura 5 - Valores reais (X) versus valores preditos (Y) de Consumo Real de Ração Semanal dos 51 lotes de matrizes aptidão leve.....	25
Figura 6 - Contribuições ou importâncias relativas, de cada uma das variáveis de entrada para Ovo/Ave/Alojada.....	26
Figura 7 - Valores reais (X) versus valores preditos (Y) de Ovo/Ave/Alojada dos 51 lotes de matrizes aptidão leve	27
Figura 8 - Contribuições ou importâncias relativas, de cada uma das variáveis de entrada para Ovos Comercial Semanal.	28
Figura 9 - Valores reais (X) versus valores preditos (Y) de Ovos Comercial Semanal dos 51 lotes de matrizes aptidão leve.	29
Figura 10 - Contribuições ou importâncias relativas, de cada uma das variáveis de entrada para Ovos Incubável Semanal.	30
Figura 11 - Valores reais (X) versus valores preditos (Y) de Ovos Incubável Semanal dos 51 lotes de matrizes aptidão leve.....	31
Figura 12 - Contribuições ou importâncias relativas, de cada uma das variáveis de entrada para Peso de Ovo Real.....	32
Figura 13 - Valores reais (X) versus valores preditos (Y) de Peso de Ovo Real dos 51 lotes de matrizes aptidão leve	33
Figura 14 - Contribuições ou importâncias relativas, de cada uma das variáveis de entrada para Produção de Ovos Real	34
Figura 15 - Valores reais (X) versus valores preditos (Y) de Produção de Ovos Real dos 51 lotes de matrizes aptidão leve.	35
Figura 16 - Contribuições ou importâncias relativas, de cada uma das variáveis de entrada para Viabilidade	36
Figura 17 -Valores reais (X) versus valores preditos (Y) de Viabilidade dos 51 lotes de matrizes aptidão leve.....	37

SUMÁRIO

1 INTRODUÇÃO	10
2 REVISÃO BIBLIOGRÁFICA	13
3 MATERIAL E MÉTODOS	17
3.1 Dados de registro	17
3.2 Análise estatística dos dados	19
3.2.1 Redes Neurais Artificiais	19
4 RESULTADOS	21
5 DISCUSSÃO	38
6 CONCLUSÃO	44
REFERÊNCIAS	Erro! Indicador não definido.
Anexo A- Autorização de Uso e Publicação	45

1 INTRODUÇÃO

A avicultura brasileira é considerada uma das mais desenvolvidas do mundo com índices de produtividade excepcionais. O sucesso da atividade é devido a programas de qualidade como genética, nutrição, manejo, biossegurança, boas práticas de produção, rastreabilidade, programas de bem-estar animal e de preservação do meio ambiente (UBA, 2008).

Ao longo dos anos, a avicultura brasileira vem apresentando altos níveis de produção, devido às novas tecnologias, melhoramento das linhagens, sanidade e nutrição das aves, com isso, a indústria conseguiu aumentar o seu potencial de produção para disponibilizar aos consumidores uma fonte proteica saudável a um custo baixo (ABPA, 2019).

Segundo Associação Brasileira de Proteína Animal (ABPA) o mercado de ovos cresceu bastante, pois é um alimento que está cada vez mais presente na mesa dos consumidores, em razão do seu baixo custo e por ser uma boa fonte de proteína que traz benefícios à saúde. De acordo com a mais recente pesquisa do Instituto Brasileiro de Geografia e Estatística (IBGE) o número de galinhas poedeiras no Brasil em 2017 teve um aumento de mais de 11% em relação a 2016.

Segundo *Certified Humane Brasil* no ano de 2017 a soma nacional de galinhas poedeiras foi de quase 243 milhões de animais, sendo que a maior concentração está na região Sudeste, seguida da região Sul. A população de poedeiras no mundo é de cerca de 4,7 bilhões de aves, sendo China, Estados Unidos, Índia, Japão, México, Rússia os maiores produtores de ovos (UBA, 2018).

De acordo com a ABPA em 2017 o consumo de ovos atingiu a quantidade de 192 unidades por brasileiro, já em 2018 subiu para 212 ovos/habitante/ano, o índice é o maior já registrado na história do setor.

A produção de ovos totalizou no ano de 2018 uma quantidade de 44,4 bilhões de unidades, mas o consumo *per capita* no Brasil ainda é baixo comparado a outros países como Japão, Paraguai, China e México. De acordo com os últimos dados de relatório anual da ABPA de 2019, o principal produtor de ovos no Brasil é São Paulo, responsável por 30,90% de alojamento de pintainhas no Brasil, seguido por Minas Gerais (10,88%); Espírito Santo (10,34%); Pernambuco (7,13%); Rio Grande do Sul (6,26%); Mato Grosso (5,69%); Paraná (6,69%); e em oitavo lugar Ceará (4,85%). Em questões de exportação Minas Gerais e Rio Grande do Sul são os maiores exportadores que, somados, correspondem a 90,34% das exportações de ovos.

O Brasil encontra-se em 7º lugar em volume de produção, do ano de 2010 para 2018 o brasileiro passou de um consumo de 148 para 212 ovos *per capita* ano, embora ainda distante dos maiores consumidores do planeta, nota-se uma busca maior no consumo de ovos e isso representa um desafio para o conjunto de instituições envolvidas na produção de ovos para a população (ABPA, 2018).

Tornar um processo de produção previsível a ponto de aperfeiçoar os recursos a serem disponibilizados é uma tarefa difícil, mas o setor vem lutando contra as características intrínsecas de imprevisibilidade da produção animal, que pode representar a diferença entre manter viável e sustentável ou fazer dispendioso e perecível (UBA, 2008). A história nos relata que, a avicultura no decorrer dos últimos anos tem mostrado que ela partiu de combinações genéticas simples visando linhagens de corte e postura com melhor produtividade, com base em empresas familiares, em geral, minifúndios, e alcançou as bolsas de valores quando as empresas cresceram se transformaram em grandes corporações (EMBRAPA, 2014).

A participação dos profissionais deveria mudar para acompanhar a evolução no setor, atualmente baseado em projeções econômicas e produtivas que atendem aos mercados nacional e internacional (ABPA, 2018).

Uma forma de minimizar isso é utilizar instrumentos que acompanham a humanidade por séculos e que constituem aspecto crucial da ciência moderna (HARARI,1994). Exercitar a observação e utilizar ferramentas matemáticas para relacionar essas observações, uma moderna ferramenta, já utilizada em vários setores da indústria global, são as redes neurais artificiais (RNA), pois elas estabelecem padrões através da compreensão de relações não lineares, ao reconhecerem padrões e transformarem em critérios que darão suporte às decisões técnicas (SILVA, 2019).

As RNAs são baseadas nos neurônios do córtex, a camada externa do cérebro, são responsáveis pelo processamento cognitivo, um novo conhecimento ou uma nova experiência pode levar a alterações estruturais no cérebro (FENEDA, 2006). Tais alterações são efetivadas por meio de um rearranjo das redes de neurônios, reforçando ou inibindo algumas sinapses (HAYKIN, 2001).

Sabe-se que o cérebro é composto de bilhões de neurônios. Um neurônio é uma célula formada por três seções com funções específicas e complementares: corpo, dendritos e axônio (GERSTNER, 2010). Os dendritos captam os estímulos recebidos em um determinado período de tempo e os transmitem ao corpo do neurônio, onde são processados, quando tais estímulos atingirem determinado limite, o corpo da célula envia novo impulso que se propaga pelo axônio e é transmitido às células vizinhas por meio de sinapses (GERSTNER, 2010). Este processo pode se repetir em várias camadas de neurônios, como resultado, a informação de entrada é processada, podendo levar o cérebro a comandar reações físicas (HAYKIN, 2001).

Uma das propriedades mais importantes de uma rede neural artificial é a capacidade de aprender por intermédio de exemplos e fazer inferências sobre o que aprendeu, melhorando gradativamente o seu desempenho (FENEDA, 2006). As redes neurais utilizam um algoritmo de aprendizagem cuja tarefa é ajustar os pesos de suas conexões (BRAGA et al., 2000).

Combinando diversos neurônios, forma-se uma rede neural artificial, são modelos que buscam simular o processamento de informação do cérebro humano (FORD, 1991). São compostas por unidades de processamentos simples, os neurônios, que se unem por meio de conexões sinápticas, de uma forma simplificada, uma rede neural artificial pode ser vista como um grafo onde os nós são os neurônios e as ligações fazem a função das sinapses gerando as predições (GERSTNER, 2010).

Os modelos desenvolvidos nessa dissertação buscam criar critérios de predição e gerenciamento dos dados zootécnicos em matrizes de aptidão postura comercial além de auxiliar as decisões técnicas da empresa.

2 REVISÃO BIBLIOGRÁFICA

As primeiras galinhas foram trazidas para o Brasil em 1500 pelas naus portuguesas comandadas por Pedro Álvares Cabral. Eram utilizadas como alimento para os tripulantes. Após a chegada ao Brasil Dom João VI Rei de Portugal, a criação comercial ganhou importância em 1808 (ARASHIRO, 1989).

A produção de ovos em escala comercial deu seus primeiros passos em Minas Gerais, justamente por volta de 1880. Os primeiros artigos científicos sobre a avicultura de postura foram escritos em 1932 pelo professor pesquisador do Instituto Biológico do Estado de São Paulo Dr. José Reis (1907-2002), médico virologista e patologista. Especializado em divulgação científica, seus artigos orientavam os criadores de aves na produção de ovos mantida em chácaras e quintais (NUNES, 2000).

Em 1934, teve início a incubação artificial, a qual deu a avicultura industrial larga escala, as aves utilizadas eram as selecionadas na região, em função da dupla aptidão, tanto para produção de carne como para o ovo (NUNES, 2000). Até então, era criada a chamada “galinha caipira”, de cores vermelha, preta e carijó, que botava ovos avermelhados (ARASHIRO, 1989).

No passado, era costume que as famílias criassem galinhas em seus quintais para consumo próprio, motivo pelo qual era muito reduzida a venda de ovos nas feiras e nas quitandas; e nesses criadouros, as fezes das aves eram utilizadas como fertilizante na produção de frutas e verduras (ARASHIRO, 1989).

As cooperativas tiveram papel fundamental na implantação da avicultura tendo em vista que a atividade requer uma estrutura complexa, pois inclui desde a manutenção de aves matrizes, incubatório de ovos, sexagem de pintainhas, cria e recria de frangas, fábrica de ração, processamento de ovos, setor de produção de ovos, e, ainda, transporte e distribuição no mercado consumidor (GUIMARÃES, 1962).

O crescimento industrial acelerou a urbanização e surgiram novas necessidades de alimentos. As aglomerações de trabalhadores, com melhor poder aquisitivo, alteraram e melhoraram seus hábitos alimentares (GUIMARÃES, 1962).

Maia (1997) reportou que as primeiras gaiolas para poedeiras chegaram ao Brasil em 1955 e ocorreram evoluções tecnológicas nas áreas de nutrição e melhoramento genético. A partir do século XX várias tecnologias vêm surgindo para melhorar índices zootécnicos na cadeia avícola (MAIA, 1997). Além das estruturas mecanizadas na avicultura que propiciam bem-estar para as aves. Modernamente, a inteligência artificial vem tendo grande importância em todos os setores da cadeia, seja sanitário ou de manejo, e as redes neurais artificiais são cada vez mais usadas.

No caso dos processos produtivos da avicultura, o objetivo é ter dados zootécnicos que reflitam a realidade da empresa para que possam ser tomadas decisões corretas.

Para Dytch (1990), o processo pelo qual uma rede neural aprende é através do exemplo e gradualmente incorpora em seu conhecimento esse aprendizado, além da capacidade de tolerar dados ambíguos, ou mesmo espúrios, que permitem utilizá-la para lidar com casos desconhecidos. Para ele, as redes neurais artificiais (RNA), utilizadas em conjunto com outras técnicas de inteligência artificial, podem fornecer ferramentas úteis para o desenvolvimento de sistemas. Podemos utilizar uma outra definição de SILVA (2019), no qual menciona que; uma RNA pode ser definida como sendo uma estrutura de processamento (rede), passível de implementação em um dispositivo eletrônico, composta por um número de unidades interconectadas (neurônios artificiais), sendo que cada unidade apresenta um comportamento específico de entrada/saída.

A utilização das RNAs na avaliação dos processos de produção da avicultura moderna já tem registro bastante substancial em várias áreas, trabalhos recentes com RNAs foram utilizadas na estimação da altura de plantios florestais de eucalipto por regressão (Martins et al., 2019). ODA (2019) utilizou as RNAs para verificar a estabilidade e a adaptabilidade de produção de grãos de soja por meio de metodologias tradicionais; LIU (2019) demonstrou que as Redes Neurais Artificiais podem ser treinadas para simular dados de pressão capilar e permeabilidade relativa em tubos capilares e com isso facilitar os processos de prospecção e extração de petróleo. Trabalhos com RNAs também foram utilizados na avaliação de matéria orgânica de solos produzindo dados acurados e com estes parâmetros permitiria minimizar riscos ambientais (FERNANDES, 2019).

Diversos trabalhos com as RNAs foram conduzidos pelo Grupo do CDPA-UFRGS desde a utilização em gerenciamento de dados produtivos e índices de sanidade em lotes de matrizes pesadas alojadas em empresa de produção de frango de corte (GUAHYBA, 2001); na busca de melhores condições de entendimento de situações de produção em um fomento de uma integração de frangos de corte (REALI, 2004); no acompanhamento de dados técnicos e indicadores de sanidade em incubatório (SALLE et al., 2005); na condução gerencial de um abatedouro de frangos de corte (PINTO, 2006); e em processo de gerenciamento amplo em uma integração de frangos de corte com o intuito de relacionar dados tanto zootécnicos quanto de sanidade numa avaliação ampla envolvendo os diversos setores desta integração (SPOHR, 2011), trabalhos realizados com cepas de *Escherichia coli* isoladas de produção aviária, como na predição da resistência antimicrobiana de cepas isoladas de frango de corte (ROCHA, 2012); na predição e classificação de índice de patogenicidade de cepas isoladas de frango de corte (ROCHA, 2006) onde as predições certas estiveram acima de 80%; na classificação de patogenicidade de cepas de origem aviária (TEJKOWSKI, 2013) no qual ao se usar como variáveis de entrada genes de virulência e motilidade e como saída a classificação de patogenicidade o índice de acerto foi acima de 90%, e avaliando a classificação de resistência antimicrobiana e de comportamento bioquímico de amostras isoladas de frango de corte com acertos na classificação de resistência acima de 80% (SALLE et al., 2009); na avaliação de depleção linfocitária na Bolsa de Fabricius (MORAES, 2010), e em conjunto com análises de imagem na adoção de critérios objetivos para diagnóstico histológico em perdas linfocitárias no timo ajudando a estabelecer critérios objetivos no diagnóstico (CARVALHO, 2013).

Em aves de postura comercial, o uso de RNAs já teve registros buscando estabelecer a eficiência como ferramenta de predição, usando lotes baseados na observação de consumo de ração e produção, utilizando linhagens distintas alojadas em condições experimentais (AHMAD, 2011); outro experimento feito para detecção automática e prévia de perdas de produção de ovos em lotes alojados em situação real de produção (RAMIREZ-MORALES, 2017); trabalhos também foram desenvolvidos para determinar uma melhor ferramenta de predição empregando lotes de postura comercial (SAVEGNANO, 2011) ou mesmo lotes de produção em codornas (FELIPE, 2015).

As RNAs já foram inclusive usadas como método de validação de outros processos de predição com possível utilidade na atividade de produção de ovos comerciais como as que utilizam Fuzzy Logic em suas avaliações (SEFEEDPARI, 2016), mesmo que esses processos derivados tenham menor capacidade preditiva (GEVREKÇI, 2019).

Todos esses trabalhos indicam que a utilização das RNAs em avicultura pode constituir um importante aperfeiçoamento nos métodos de gerenciamento das atividades relacionadas à produção avícola.

O objetivo desse trabalho é verificar se é possível utilizar as RNAs na predição dos indicadores de produção em aves matrizeiras de aptidão postura comercial.

3 MATERIAL E MÉTODOS

3.1 Dados de registro

O estudo corresponde a séries históricas de dados de uma empresa multiplicadora de genética no estado do Rio Grande do Sul, durante os anos de 2007 a 2014.

As informações utilizadas para a elaboração das RNAs são provenientes de matrizes de aptidão postura comercial localizadas em diferentes núcleos no estado do RS. A empresa possui granjas próprias e integração de recria e produção, detém no Brasil as linhagens Isa Brown (ovos vermelhos) e Bovans Withe (ovos brancos).

Foi usado um total de 51 lotes totalizando 405.511 de aves avaliadas com média de idade de 75 semanas de linhagens Isabrown e Bovans Whithe. A empresa participante do experimento forneceu um banco de dados com informações de vários lotes pelo período compreendido de sete anos.

As informações sobre os lotes utilizados para a formação das RNAs seguem abaixo:

Fêmeas:

- idade do nascimento;
- idade em semanas;
- número do lote;
- mortalidade;
- aves descartadas;
- saldo atual de aves semanal;
- *standart* da linhagem;
- viabilidade;
- peso da ave;
- uniformidade.

Machos:

- idade em semanas;
- mortalidade;
- aves descartadas;

- saldo atual de aves semanal;
- *standart* da linhagem;
- viabilidade;
- peso da ave;
- uniformidade.

Ovos:

- total produzidos semanalmente;
- ovos acumulados;
- percentual de produção da linhagem;
- *standart* de produção;
- ovo por ave alojada;
- quantidade de ovos incubáveis semanal;
- quantidade de ovos incubáveis acumulado;
- percentual de aproveitamento;
- quantidade de ovos comerciais semanais e acumulados;
- quantidade de ovos trincados semanais;
- quantidade de ovos que foram para o lixo ;
- percentual e quantidade de ovos de cama;
- peso do ovo.

Ração:

- quantidade e dia da entrega;
- estoque de ração na granja;
- tipo de ração;
- quantidade de consumo semanal;
- consumo real por ave/dia;
- *standart* do consumo por ave/dia;

3.2 Análise estatística dos dados

A estatística descritiva dos dados foi realizada utilizando-se o programa computacional Sigmastat for Windows, versão 2.03.

3.2.1 Redes Neurais Artificiais

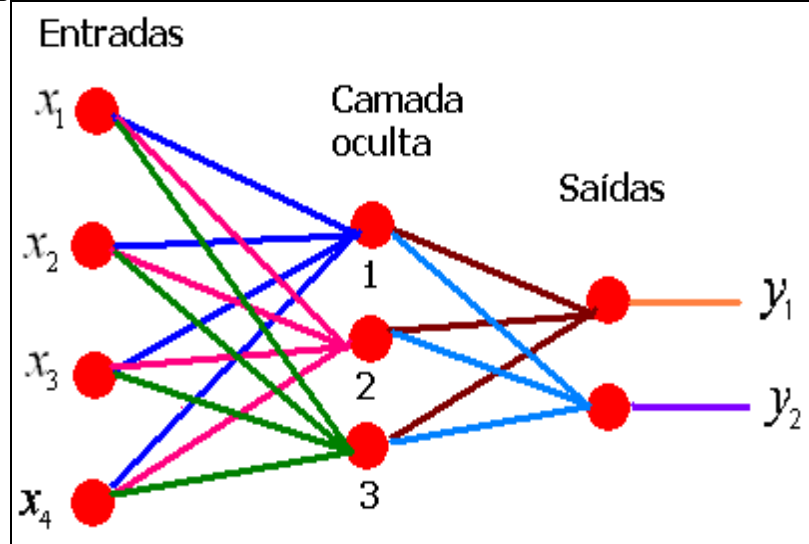
Nesse trabalho, o termo “entrada” identifica as variáveis escolhidas para o cálculo do modelo preditivo e a palavra “saída” a variável a ser predita.

Para a construção das redes neurais artificiais foram utilizados os programas computacionais *NeuroShell®Classifier* e *NeuroShell® Predictor*, desenvolvidos pela *Ward Systems Group*. A arquitetura empregada na construção da rede é única e foi desenvolvida para que ela “aprenda” rapidamente e não necessite de um conjunto de dados de teste para melhorar sua habilidade para generalizar, ou seja, dar respostas razoáveis para dados que ela nunca tenha visto anteriormente. Para isso, a estratégia de treinamento usa uma rede neural que dinamicamente cria “neurônios escondidos” para construir um modelo que generalize bem.

A rede inicia encontrando relações lineares entre as importâncias relativas das variáveis de entradas e as de saídas (DVMEDIA, 2013). São atribuídos pesos as ligações entre os neurônios de entrada e saída, depois que essa relação é encontrada, outros neurônios são adicionados à camada oculta para que relações não lineares possam ser identificadas. Os valores de entrada na primeira camada são multiplicados pelos pesos e passados a segunda, que é oculta (DVMEDIA, 2013). Os neurônios da camada ativam, ou produzem, saídas que são baseadas na soma dos valores pesados que passaram por ela. A camada oculta transmite os valores para a camada de saída da mesma forma e os valores desejados são obtidos (SILVA, 1998).

A rede aprende ajustando os pesos das interconexões entre as camadas. As respostas que a rede está produzindo são repetidamente comparadas com as respostas corretas e, em cada vez, os pesos das conexões são ligeiramente ajustados na direção da resposta certa. São adicionados tanto neurônios ocultos quanto forem necessários, até o máximo de 150, para retratar as características dos bancos de dados. Se o problema pode ser aprendido, ele desenvolve um conjunto estável de pesos que irão produzir boas respostas para todas as decisões ou predições da amostra (SILVA, 1998).

Figura 1- Exemplo esquemático da arquitetura de rede neural



Fonte: Adaptado Dvmedia, 2013.

O modelo de redes neurais artificiais das variáveis preditas (saídas) foi comparado e selecionado como melhores, baseado no Coeficiente de Determinação Múltipla (R^2) no Quadrado Médio do Erro (QME) bem como a análise de gráficos, plotando a predição da rede *versus* a predição menos o real. O R^2 foi calculado através da fórmula $R^2=1-(SSE/yy)$, onde $SSE = \sum (\text{valor real} - \text{valor predito})^2$ e $SSyy = \sum (\text{valor real} - \text{média dos valores})^2$. O QME foi calculado como sendo a média dos valores reais menos os valores preditos, elevado a potência 2 [QME = média (valores reais – preditos)²].

Para o treinamento das redes foram utilizados 2.370 linhas, outras 593 serviram como testes para validação das predições, ou seja, 74,9% de treinamento e 25,1% para validação, significa que a rede foi bem treinada.

4 RESULTADOS

As tabelas a seguir apresentam os resultados das RNAs quando aplicadas aos 51 lotes de matrizes de aptidão postura comercial pelo período de junho de 2007 a agosto de 2014.

Os resultados demonstram que as redes neurais foram bem ajustadas apresentando Coeficiente de Determinação Múltipla (R^2) elevado, salientando que R^2 quanto mais se aproximar de 1 maior precisão.

Os dados subsequentes estão relacionados a RNA para Ovos Produzidos Semanalmente:

Tabela 1- Características do treinamento modelo de rede neural para predição da saída de Ovos Produzidos Semanalmente

Estatística de predição	Valores
R^2	0,994198
Erro médio	384,3674
Correlação	0,997102
QME	637681,4
RQME	798,5496

R^2 - Coeficiente de Determinação Múltipla; QME – Quadrado Médio do Erro; RQME – Raiz Quadrada Média do Erro.

Tabela 2- Importância Relativas das variáveis semanal

Entradas	Importância relativa
Produção acumulada	0,229
Ovos incubáveis semanal	0,228
Idade em semanas	0,226
Ovos comerciais semanais	0,171
Número de aves fêmeas	0,066

Figura 2- Contribuições ou importâncias relativas, de cada uma das variáveis de entrada para Ovos Produzidos Semanalmente




Tabela 3-Validação do modelo de redes neurais para predição de Ovos Produzidos semanalmente


Estatística de predição	Valores
R ²	0,993693
Erro médio	427,2444
Correlação	0,996845
QME	733785,3
RQME	856,6127

R² - Coeficiente de Determinação Múltipla; QME – Quadrado Médio do Erro; RQME – Raiz Quadrada Média do Erro.

Na Figura 3 é apresentada uma visão conjunta da totalidade dos lotes validados para Ovos Produzidos Semanal.

Actual (X-axis) vs Predicted (Y-axis)

Figura 3- Valores reais (X) versus valores preditos (Y) de Ovos Produzidos Semanal dos 51 lotes de matrizes aptidão leve



Os dados subsequentes estão relacionados a RNA para Consumo Real de Ração Semanal:

Tabela 4- Características do treinamento do modelo de rede neural para predição da saída de Consumo Real de Ração Semanal

Estatística de predição	Valores
R ²	0,766657
Erro médio	7,772628
Correlação	0,876182
QME	283,7911
RQME	16,8461

R² - Coeficiente de Determinação Múltipla; QME – Quadrado Médio do Erro; RQME – Raiz Quadrada Média do Erro.

A Tabela 5 demonstra as contribuições, ou importância relativas, de cada uma das variáveis de entrada para saída de Consumo Real de Ração Semanal.

Tabela 5- contribuições, ou importância relativas, de cada uma das variáveis de entrada para saída de Consumo Real de Ração Semanalmente

Entradas	Importância relativa
Ovos comerciais semanal	0,113
Idade em semanas	0,110
Ovo ave alojada semanal	0,093
Produção acumulada	0,072
Lixo semanal	0,058
Ovo incubável semanal	0,048
Trincado semanal	0,035

Figura 4- Contribuições ou importâncias relativas, de cada uma das variáveis de entrada para Consumo Real de Ração Semanal.




Tabela 6- Validação do modelo de redes neurais para predição de Consumo Real de Ração Semanal


Estatística de predição	Valores
R ²	0,770696
Erro médio	7,69536
Correlação	0,88149
QME	260,0547
RQME	16,12621

R² - Coeficiente de Determinação Múltipla; QME – Quadrado Médio do Erro; RQME – Raiz Quadrada Média do Erro.

Na Figura 5 é apresentada uma visão conjunta da totalidade dos lotes validados para Consumo Real de Ração Semanal.

Actual (X-axis) vs Predicted (Y-axis)

Figura 5- Valores reais (X) versus valores preditos (Y) de Consumo Real de Ração Semanal dos 51 lotes de matrizes aptidão leve



Os dados subsequentes estão relacionados a RNA para Ovo/Ave/Alojada:

Tabela 7- Características do treinamento do modelo de rede neural para predição da saída de Ovo/Ave/Alojada


Estatística de predição	Valores
R ²	0,966919
Erro médio	81793,25
Correlação	0,983326
QME	1,27E+11
RQME	355877,2

R² - Coeficiente de Determinação Múltipla; QME – Quadrado Médio do Erro; RQME – Raiz Quadrada Média do Erro.

A Tabela 8 demonstra as contribuições, ou importância relativas, de cada uma das variáveis de entrada para saída de Ovo/Ave/Alojada:

Tabela 8- Importância relativa das variáveis de entrada e saída de Ovo/Ave/Alojada

Entradas	Importância relativa
Número de aves macho	0,308
Trincado semanal	0,183
Número de aves fêmea	0,160
Ovos produzidos semanal	0,125
Produção acumulada	0,116
Idade em semanas	0,038
Descarte de fêmeas	0,031

Figura 6- Contribuições ou importâncias relativas, de cada uma das variáveis de entrada para Ovo/Ave/Alojada.**Tabela 9-** validação de redes neurais para predição de Ovo/Ave/Alojada

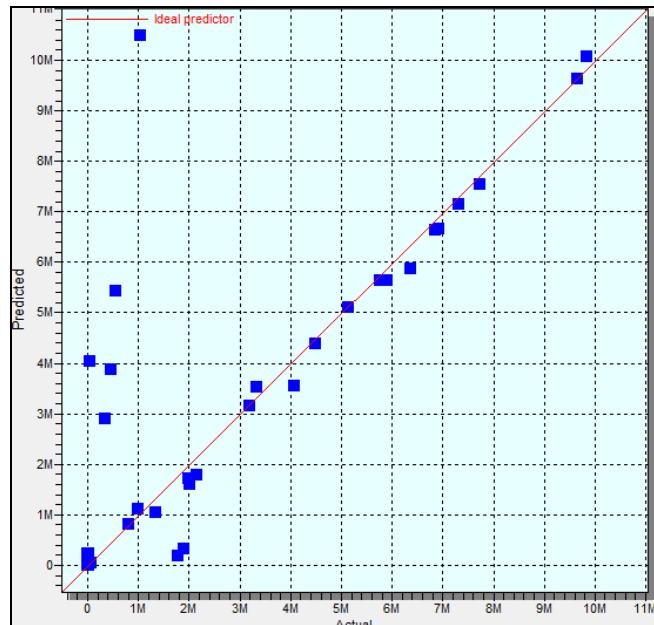
Estatística de predição	Valores
R ²	0,724993
Erro médio	175701
Correlação	0,881667
QME	7,963+11
RQME	892401,8

R² - Coeficiente de Determinação Múltipla; QME – Quadrado Médio do Erro; RQME – Raiz Quadrada Média do Erro.

Na Figura 7 é apresentada uma visão conjunta da totalidade dos lotes validados para Ovo/Ave/Alojada.

Actual (X-axis) vs Predicted (Y-axis)

Figura 7- Valores reais (X) versus valores preditos (Y) de Ovo/Ave/Alojada dos 51 lotes de matrizes aptidão leve



Os dados subsequentes estão relacionados a RNA para Ovos Comercial Semanal:

Tabela 10- Características do treinamento do modelo de rede neural para predição da saída de Ovos Comercial Semanal


Estatística de predição	Valores
R ²	0,938908
Erro médio	469,7526
Correlação	0,969444
QME	2,12E+06
RQME	1457,563

R² - Coeficiente de Determinação Múltipla; QME – Quadrado Médio do Erro; RQME – Raiz Quadrada Média do Erro.

Tabela 11- Demonstração das importâncias relativas de cada variável de entrada para saída de Ovos Comercial Semanal

Entradas	Importância relativa
Idade em semanas	0,324
Produção acumulada	0,321
Ovos produzidos semanal	0,278
Ovos incubáveis semanal	0,039
FVAAR	0,028
Número de aves macho	0,009

Figura 8- Contribuições ou importâncias relativas, de cada uma das variáveis de entrada para Ovos Comercial Semanal.



A Tabela 12 mostra a validação do modelo de redes neurais para predição de Ovos Comercial Semanal.

Tabela 12- Validação do modelo de redes neurais para predição de Ovos Comercial Semanal


Estatística de predição	Valores
R ²	0,772552
Erro médio	699,2906
Correlação	0,89351
QME	8,07E+06
RQME	2840,286

R² - Coeficiente de Determinação Múltipla; QME – Quadrado Médio do Erro; RQME – Raiz Quadrada Média do Erro.

Na Figura 9 é apresentada uma visão conjunta da totalidade dos lotes validados para Ovos Comercial Semanal.

Actual (X-axis) vs Predicted (Y-axis)

Figura 9- Valores reais (X) versus valores preditos (Y) de Ovos Comercial Semanal dos 51 lotes de matrizes aptidão leve.



Os dados subsequentes estão relacionados a RNA para Ovos Incubável Semanal:

Tabela 13- Características do treinamento do modelo de rede neural para predição da saída de Ovos Incubável Semanal


Estatística de predição	Valores
R ²	0,997316
Erro médio	218,679
Correlação	0,998657
QME	158375,1
RQME	397,9637

R² - Coeficiente de Determinação Múltipla; QME – Quadrado Médio do Erro; RQME – Raiz Quadrada Média do Erro.

A Tabela 14 demonstra as contribuições, ou importância relativas, de cada uma das variáveis de entrada para saída de Ovos Incubável Semanal.

Tabela 14- Importâncias relativas das variáveis de entrada para saída de Ovos Incubáveis Semanal

Entradas	Importância relativa
Idade em semanas	0,340
Produção acumulada	0,339
Ovos produzidos semanal	0,141
Número de aves macho	0,087
Ovos comerciais semanal	0,046
Número de aves fêmea	0,039

Figura 10- Contribuições ou importâncias relativas, de cada uma das variáveis de entrada para Ovos Incubável Semanal**Tabela 15-** Validação do modelo de redes neurais para predição de Ovos Incubável Semanal

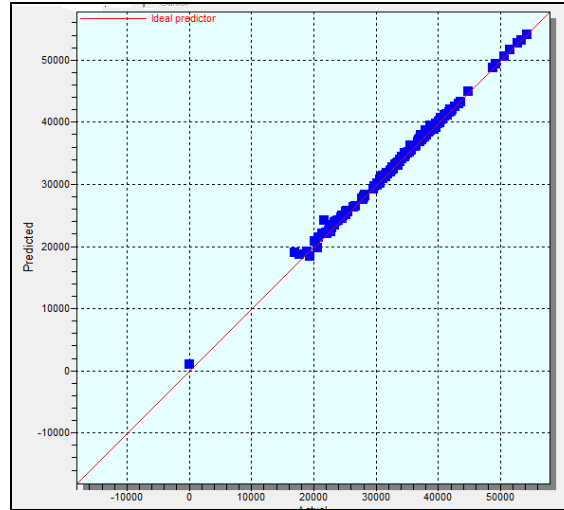
Estatística de predição	Valores
R ²	0,997763
Erro médio	288,5308
Correlação	0,99897
QME	144896,4
RQME	380,6526

R² - Coeficiente de Determinação Múltipla; QME – Quadrado Médio do Erro; RQME – Raiz Quadrada Média do Erro.

Na Figura 11 é apresentada uma visão conjunta da totalidade dos lotes validados para Ovos Incubável Semanal.

Actual (X-axis) vs Predicted (Y-axis)

Figura 11- Valores reais (X) versus valores preditos (Y) de Ovos Incubável Semanal dos 51 lotes de matrizes aptidão leve



Os dados subsequentes estão relacionados a RNA para Peso de Ovo Real:

Tabela 16- Características do treinamento do modelo de rede neural para predição da saída de Peso de Ovo Real

Estatística de predição	Valores
R ²	0,715333
Erro médio	1,389115
Correlação	0,847361
QME	7,439057
RQME	2,727463

R² - Coeficiente de Determinação Múltipla; QME – Quadrado Médio do Erro; RQME – Raiz Quadrada Média do Erro.

A Tabela 17 demonstra as contribuições, ou importância relativas, de cada uma das variáveis de entrada para saída de Peso de Ovo Real.

Tabela 17- Demonstração das importâncias relativas de cada uma variável de entrada para saída de Peso de Ovo Real

Entradas	Importância relativa
Número de aves fêmea	0,170
Ovos incubáveis semanal	0,167
Ovos comercial semanal	0,135
Produção acumulada	0,133
Número de aves macho	0,093
Mortalidade aves fêmea	0,089
Peso fêmea real (Kg)	0,084

Figura 12- Contribuições ou importâncias relativas, de cada uma das variáveis de entrada para Peso de Ovo Real




Tabela 18- Validação do modelo de redes neurais para predição de Peso de Ovo Real


Estatística de predição	Valores
R ²	0,717876
Erro médio	1,459558
Correlação	0,86938
QME	4,641196
RQME	2,154344

R² - Coeficiente de Determinação Múltipla; QME – Quadrado Médio do Erro; RQME – Raiz Quadrada Média do Erro.

Na Figura 13 é apresentada uma visão conjunta da totalidade dos lotes validados para Peso de Ovo Real.

Actual (X-axis) vs Predicted (Y-axis)

Figura 13-Valores reais (X) versus valores preditos (Y) de Peso de Ovo Real dos 51 lotes de matrizes aptidão leve



Os dados subsequentes estão relacionados a RNA para Produção do Ovo Real:

Tabela 19- Características do treinamento do modelo de rede neural para predição da saída de Produção do Ovos Real

Estatística de predição	Valores
R ²	0,877222
Erro médio	3,62838
Correlação	0,939762
QME	49,23377
RQME	7,016678

R² - Coeficiente de Determinação Múltipla; QME – Quadrado Médio do Erro; RQME – Raiz Quadrada Média do Erro.

A Tabela 20 demonstra as contribuições, ou importância relativas, de cada uma das variáveis de entrada para saída de Produção de Ovos Real.

Tabela 20- Contribuições ou importâncias relativas de cada uma das variáveis de entrada para saída de Produção de Ovos Real

Entradas	Importância relativa
Idade semanal	0,329
Número de aves fêmea	0,328
Número de aves macho	0,190
Mortalidade aves fêmea	0,117
Descarte fêmea	0,021
Mortalidade macho	0,015

Figura 14- Contribuições ou importâncias relativas, de cada uma das variáveis de entrada para Produção de Ovos Real




Tabela 21- Validação do modelo de redes neurais para predição de Produção de Ovos Real


Estatística de predição	Valores
R ²	0,821012
Erro médio	3,588073
Correlação	0,90655
QME	58,34798
RQME	7,638585

R² - Coeficiente de Determinação Múltipla; QME – Quadrado Médio do Erro; RQME – Raiz Quadrada Média do Erro.

Na Figura 15 é apresentada uma visão conjunta da totalidade dos lotes validados para Produção de Ovos Real.

Actual (X-axis) vs Predicted (Y-axis)

Figura 15-Valores reais (X) versus valores preditos (Y) de Produção de Ovos Real dos 51 lotes de matrizes aptidão leve.



Os dados subsequentes estão relacionados a RNA para Viabilidade:

Tabela 22- Características do treinamento do modelo de rede neural para predição da saída de Viabilidade


Estatística de predição	Valores
R ²	0,972904
Erro médio	1,306314
Correlação	0,986426
QME	23,21462
RQME	4,818155

R² - Coeficiente de Determinação Múltipla; QME – Quadrado Médio do Erro; RQME – Raiz Quadrada Média do Erro.

A Tabela 23 demonstra as contribuições, ou importância relativas, de cada uma das variáveis de entrada para Viabilidade.

Tabela 23- Contribuições ou importâncias relativas de cada uma das variáveis de entrada para Viabilidade

Entradas	Importância relativa
Número de aves macho	0,185
Número de aves fêmea	0,185
Idade semanal	0,153
Trincado semanal	0,130
Ovo incubável semanal	0,086
Ovo/ave/alojada/real	0,070

Figura 16- Contribuições ou importâncias relativas, de cada uma das variáveis de entrada para Viabilidade**Tabela 24-** Validação do modelo de redes neurais para predição de Viabilidade


Estatística de predição	Valores
R ²	0,967434
Erro médio	1,159754
Correlação	0,983587
QME	25,69118
RQME	5,068647

R² - Coeficiente de Determinação Múltipla; QME – Quadrado Médio do Erro; RQME – Raiz Quadrada Média do Erro.

Na Figura 17 é apresentada uma visão conjunta da totalidade dos lotes validados para Viabilidade.

Actual (X-axis) vs Predicted (Y-axis)

Figura 17-Valores reais (X) versus valores preditos (Y) de Viabilidade dos 51 lotes de matrizes aptidão leve



5 DISCUSSÃO

O presente trabalho teve como objetivo principal demonstrar que as redes neurais artificiais foram capazes de prever os indicadores de produção em aves matrizeiras de aptidão postura comercial nas diferentes etapas da cadeia avícola. Os trabalhos que mais se aproximaram foram os que tratavam de utilização de redes neurais artificiais para explicar os fenômenos ocorridos em reprodutoras pesadas tanto na fase de recria (SALLE et al., 2001) como na fase de produção (SALLE et al., 2003).

Outros pesquisadores já demonstraram que essa metodologia pode ser utilizada para o gerenciamento de vários setores da cadeia avícola como no frango de corte (REALI, 2004), no incubatório (SALLE, 2005) e no frigorífico (PINTO, 2006).

Os dados zootécnicos fornecidos pela empresa matrizeira foram, de forma geral, bastante homogêneos e representaram a realidade dos lotes. Foram utilizados registros de 2007 a 2014 usando cerca de 51 lotes das linhagens de matrizes Isa Brown e Bovans Withe.

Os dados fornecidas para análise que geraram as redes foram disponibilizadas pela empresa seguindo uma ordem de acordo com o que é utilizada pelo produtor na granja: ovos produzidos semanal, ovo comercial semanal, ovo incubável semanal, peso do ovo real, produção de ovos semanal, viabilidade, ovo/ave/alojada, consumo de ração, entre outros.

O modelo utilizado para o treinamento da rede denominada “ovo produzido semanal” foi preciso, visto que tiveram os seguintes resultados $R^2 = 0,994198$, Erro Médio = 384,3674, Correlação = 0,997102, QME = 637681,4 e RQME = 798,5496, conforme Tabela 1.

As contribuições, ou importância relativas, de cada uma das variáveis de entrada para saída desse modelo foram: produção acumulada; ovo incubável semanal; idade em semanas; ovo comercial semanal e número de aves fêmeas. Esses dados geraram previsões muito assertivas para ovos produzidos semanal, que pode ser corroborado através dos resultados $R^2 0,993693$, Erro Médio = 427,2444, Correlação = 0,996845, QME = 733785,3 e RQME = 856,6127 (Tabela 3), a Figura 3 ilustra bem a precisão da previsão.

De acordo com SALLE (2003), resultados de R^2 e Correlação ao se aproximarem do valor 1 indicam validação de melhor qualidade, ao se distanciarem deste valor tem sua qualidade diminuída.

O resultado de Erro Médio (427,2444) e QME (733785,3) mesmo sendo elevado também tiveram resultados ajustados para rede, todavia, os valores absolutos deste índice (ovos produzidos semanal) variaram. Esse fenômeno ocorreu em função da empresa em estudo adquirir diferentes quantidades de aves para cada lote, gerando em alguns casos distorção nos dados de ovo produzido semanal para aplicação das redes.

Para o treinamento do modelo “consumo real de ração semanal” na Tabela 4, os valores de R^2 de 0,766657, mesmo não sendo tão preciso para predição, contudo foram úteis nessa pesquisa. As contribuições mais relevantes, dado apresentado na Tabela 5, foram: ovo comercial semanal; idade em semanas; ovo/ave/alojada; produção acumulada; lixo semanal; ovo incubável semanal e ovo trincado semanal. Há uma relação estreita entre o consumo de ração e todas essas importâncias relativas, no qual variaram de 0,113 (ovo comercial semanal) a 0,035 (ovo trincado semanal). Na validação da RNA o valor de R^2 foi 0,770696, como aparece na Tabela 6, esse valor confirma que essa rede é adequada para predição da saída para consumo real de ração semanal.

Como um importante elemento na discussão é fundamental considerar as fases de consumo de ração dessas aves, que podem variar de 9g no primeiro dia de vida até 123g quando as aves estão no pico de produção. Dessa forma, temos que levar em consideração outro fator, a sazonalidade principalmente no estado do Rio Grande do Sul, onde temos uma alta amplitude térmica que, conseqüentemente, afetou o consumo padrão de ração, gerando dados desuniformes em alguns casos. Vale salientar que as aves estudadas foram criadas em ambientes “abertos”, ou seja, somente manejo de cortinas e ventiladores para controlar a temperatura. Esses fatores, entre outros, tiveram importância em alguns erros na predição, podemos afirmar através do estudo realizado por Borbas & Minville (1997), no qual avaliaram os efeitos da temperatura ambiental em aves poedeiras de diferentes linhagens e, ao submeter as aves a ambientes com temperatura de 21 °C e 35 °C, observaram que houve uma redução de 16% na ingestão de alimentos, 13 % no número de ovos e 4% no peso do ovo. Assim sendo, a construção de rede com predição mais acurada para a saída consumo real de ração semanal seria mais precisa se o ambiente dos galpões fosse controlado.

A característica do treinamento do modelo para predição “ovo/ave/alojada”, representada na Tabela 7, gerou uma rede cujo valores para a fase de treinamento foram de $R^2 = 0,966919$ e Correlação = 0,983326, com grande capacidade de acerto.

As entradas que se mostraram mais importantes, dado apresentado na Tabela 8, foram: número de aves machos; trincado semanal; número de aves fêmeas; ovos produzidos semanal; produção acumulada; idade em semanas e descarte de fêmeas, esses parâmetros têm uma fundamental importância para geração dessa unidade.

Na validação dessa rede os valores foram $R^2 = 0,724993$ e Correlação = 0,881667, como aparece na Tabela 9. A capacidade de predição, que pode ser observada na Figura 7, fica comprometida ao se verificar a distribuição dos pontos comparando a predição aos dados reais. A rede também demonstra para alguns *outliers*, ou seja, fora da curva, esses dados foram rastreados na planilha de produção e verificou-se que houve erros de fórmulas, já no item produção de ovos, ocorreu erro de digitalização. É possível concluir que as RNA, além de predizerem com eficiência os dados zootécnicos, foram capazes de elucidar algumas falhas nas planilhas de dados da empresa contribuindo para correção das mesmas.

Podemos observar na Tabela 10 as características do treinamento do modelo de rede neural para predição da saída de “ovos comercial semanal”, conforme os resultados de $R^2 = 0,938908$ e Correlação = 0,969444 indica que a rede deverá ser boa para a predição. As características de entrada que mais contribuíram podem ser observadas na Tabela 11, foram: idade em semanas; produção acumulada; ovos produzidos semanal; ovo incubável semanal; Fêmea Vendida Ave Alojada Real (FVAAR) e número de aves macho.

Para validação observa - se um Erro Médio de 699,2906, aparentemente elevado, que pode ser explicado pela figura 9, podemos observar uma visão conjunta da totalidade dos lotes validados para ovos comercial semanal, no qual estão muito próximas (valores preditos *versus* valores reais), porém podemos observar pontos fora da curva ocasionados por fatores como não lançamento de informações na semana por parte do produtor; erro de digitalização; períodos de stress que alteram significativamente a quantidade de ovos comerciais na semana; “muda forçada” realizada em alguns lotes em final de produção; assim sendo, percebe-se que todos esses fatores contribuíram para que dificultasse a predição da rede nesse caso.

Observamos o modelo treinado para “ovos incubável semanal” está bem ajustado tanto os resultados de “entrada” quanto os de “saída”. Importante ressaltar os seguintes resultados conforme Tabela 13, $R^2 = 0,997316$, Erro Médio = 218,679, Correlação = 0,998657, QME = 158375,1 e RQME = 397,9637.

As importâncias relativas, de cada uma das variáveis do modelo foram: idade em semanas; produção acumulada; ovos produzidos semanal; número de aves macho; ovo comercial semanal e número de aves fêmeas.

Para validação desse modelo verificamos na Tabela 15 os seguintes resultados, $R^2 = 0,997763$, Erro Médio = 288,5308, Correlação = 0,99897, QME = 144896,4 e RQME = 380,6526 que ilustra bem a precisão da predição para ovos incubável semanal.

Conforme Figura 11, podemos concluir que o modelo foi bem ajustado para predição, essa precisão está relacionada ao correto preenchimento dos registros de ovos incubáveis na granja, isso ocorre pois nessa empresa a remuneração do produtor era apenas por ovos incubável entregue.

Para o treinamento da rede neural para “peso de ovo real” foram $R^2 = 0,715333$ e Correlação = 0,847361. As principais importâncias relativas das variáveis de entrada para saída foram: número de aves fêmea; ovo incubável semanal e produção acumulada conforme Tabela 17.

Embora tenha tido uma boa predição, apresentou dados estatísticos para validação inferiores comparados aos demais resultados apresentados nesse trabalho, de acordo com a Tabela 18 obtivemos resultados de $R^2 = 0,717876$, Erro Médio = 1,459558, Correlação = 0,86938, QME = 4,641196 e RQME = 2,154344.

Como justificativa para os resultados é importante salientar que; as aves avaliadas na granja foram submetidas a vários fatores que tiveram influência para essa predição, foi observado que nessa empresa alguns lotes tiveram baixa uniformidade no pico de produção, além de ocorrer mudanças drásticas na nutrição de alguns lotes em períodos sazonais, essas variáveis contribuíram para se ter diferenças no padrão de “peso do ovo real”. RIBEIRO (2019) utilizou RNAs com frangos de corte para gerar planos de ação para correção de manejo em função das diferentes variáveis, buscando corrigir os erros, se essa prática fosse utilizada nos lotes estudados, várias anomalias teriam sido corrigidas gerando dados mais assertivos.

Para a variável “produção de ovos real” o R^2 do processo de treinamento como está apresentado na Tabela 19, tem como valor 0,877222 indicando que a rede demonstrou ser boa para predição. As contribuições mais relevantes como parâmetros de entrada, de acordo com a Tabela 20, foram: Idade semanal; número de aves fêmeas; número de aves macho; mortalidade aves fêmea; descarte fêmea e mortalidade macho.

O valor de R^2 para a validação da rede é de 0,821012, como aparece na Tabela 21, confirmando que a rede construída para a saída “produção de ovos real” é de boa qualidade.

A Figura 15 evidencia a capacidade de predição da RNA para a saída desse modelo ainda que a distribuição dos pontos relativos à predição *versus* realidade presente, essas anomalias vêm ao encontro com os acontecimentos ocorridos para a predição “peso de ovo real”, no qual tivemos algumas interferências externas que corroboraram para o resultado.

No caso da variável de saída “viabilidade” o R^2 do processo de treinamento, como Tabela 22, no valor de 0,972904 indica uma rede bem ajustada para predição. As características de entrada mais relevantes, dado apresentado na Tabela 23, foram: número de aves macho; número de aves fêmea; idade semanal; trincado semanal; ovo incubável semanal e ovo/ave/alojada.

É possível confirmar a eficiência através da validação observada na Tabela 24, $R^2 = 0,967434$, Erro médio = 1,159754, Correlação = 0,983587, QME = 25,69118 e RQME = 5,068647, onde fica evidenciado que a capacidade de predição da RNA para a saída “viabilidade” é muito boa, já que, a distribuição gráfica dos dados previstos em comparação aos dados reais conforme Figura 17 estão muito próximas.

Como discussão dessa rede vale salientar que tivemos várias intercorrências em alguns lotes estudados, um deles foi o fato da empresa estudada receber matrizes de outra companhia avozeira e alguns apresentarem onfalite nos primeiros dias de vida e terem alta mortalidade, seleção (descarte) pós pico de produção ajudou a distorcer a curva, outro fator avaliado foi mortalidade por “amontoamento” ocorrido por linhagem Isa Brown (vermelha), sabe se que aves de mesma aptidão tem diferentes comportamentos, baseado nisso, um trabalho científico realizado por HAITAO (2017) utilizou um método com rede neural convolucional automática (CNN) para reconhecer o comportamento das galinhas usando um sensor Kinect, isso ajudou a auxiliar no manejo das diferentes linhagens.

Mesmo com esses fatores que poderiam dificultar os resultados, podemos dizer que as RNAs tiveram uma boa predição.

Finalmente, podemos observar que as redes neurais artificiais foram capazes de realizar predições exatas e, assim, fazer uma avaliação de risco com oito modelos ajustados. Porém, talvez ainda mais importante, ao apresentar as importâncias relativas das variáveis de entrada oferece uma forma de gerenciamento de risco.

6 CONCLUSÃO

Os modelos desenvolvidos nessa dissertação permitem criar critérios que auxiliarão como suporte, as decisões técnicas da empresa.

É possível utilizar as RNAs para prever as informações alocadas dos lotes de matrizes de aptidão postura comercial, gerando previsões úteis nas oito redes apresentadas neste trabalho, além de apontar falhas nos dados da planilha de produção da empresa contribuindo para sua correção.

REFERÊNCIAS

- ABPA (Associação Brasileira de Proteína Animal). **Relatório Anual de 2019**. Disponível na Internet: www.abpa-br.com.br/storage/files/relatorio-anual-2018.pdf (Acesso em 05 de março de 2019)
- AHMAD, H.A. Egg production forecasting: Determining eficiente modeling approaches. **Journal of Applied Poultry Research**. v.20, p.463-473,2011.
- ARASHIRO, O. **A história da avicultura do Brasil**. São Paulo: Ed. Gessulli Editores, 179 p. 1989
- AVISITE. Estatísticas e Preços. Disponível na Internet: <https://www.avisite.com.br/index.php?page=estatisticaseprecos&acao=exportacao> (Acesso em 05 de março de 2019)
- BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000.
- BORBAS, A.; MINVELLE, F. **Response a la chaleur de poules pondeuses issues de lignees selectionnes pour une faible (R-) ou forte (R+) consommation alimentaire resrduelle**. *Genetics, selection, Evolution*, v. 29, n. 3, p. 279-290, 1997.
- CARVALHO, D. **Dissertação de Mestrado**: Avaliação da Perda Linfocitária do Timo de Frangos de Corte Utilizando Sistema de Análís Digital de Depleção Linfóide (ADDL) . Porto Alegre, UFRGS, Faculdade de Veterinária, PPGCV,74p.,2013.
- CERTIFIED HUMANA BRASIL, **Criação e consumo de ovos**. Disponível em: <https://certifiedhumanebrasil.org/galinhas-poedeiras-criacao-consumo-ovos-sobem/> (Acesso em 22 de junho de 2019)
- DVMEDIA. **Redes Neurais Artificiais, Algoritmos Backpropagation**. Disponível na Internet: <https://www.devmedia.com.br/redes-neurais-artificiais-algoritmo-backpropagation/28559> (Acesso em 03 de março de 2019)
- DYTCH, H.E. Artificial neural networks and their use in quantitative pathology. **Analytical and Quantitative Cytology and Histology**. v.12, p. 379-393, 1990.
- EMBRAPA Suínos e Aves. Disponível em: <https://www.embrapa.br/suinos-e-aves>. Acesso em: 18 jun. 2019
- FENEDA E.; **Redes neurais e sua aplicação em sistemas de recuperação de informação**, Brasília, v. 35, n. 1, p. 25-30, jan./abr. 2006

FELIPE, V.P.S. Using multiple regression, Bayesian networks and artificial neural networks for prediction of total egg production in European quails based on earlier expressed phenotypes. **Poultry Science**.v.94, p.772-780,2015.

FERNANDES, H. Estimation of soil organic matter content by modeling with artificial neural networks. **Geoderma** .v.350,p.46-51,2019.

FORD, N. *Expert systems and artificial intelligence: an information manager's guide*. London: Library Association Publishing, 1991.

GERSTNER W., *Frontiers in Synaptic Neuroscience* **2**, 50 (2010).

GEVREKÇI, Y. A fuzzy logic application to predict egg production on laying hens. **Kafkas Univ Vet Fak Derg**, v.25, p. 111-118, 2019.

GUAHYBA, A.S. **Tese de Doutorado**: Utilização de inteligência artificial (redes neurais artificiais) no gerenciamento de reprodutoras pesadas. Porto Alegre, UFRGS, Faculdade de Veterinária, PPGCV,116p.,2001.

GUIMARÃES, Mario Mozzei. Avicultura acompanhou surto industrial. **Coopercotia**, São Paulo, janeiro, p. 22-28, 1962.

HAITAO P.; LIANT J.; MINGQU F.; Automatic Recognition of Flock Behavior of Chickens with Convolutional Neural Network and Kinect Sensor, **International Journal of Pattern Recognition and Artificial Intelligence**, V. 32, n. 7, set. 2017.

HARARI, J.; CAMARGO, R. **Simulação da propagação das nove principais componentes de maré na plataforma sudeste brasileira através de modelo numérico hidrodinâmico**. Boletim do Instituto Oceanográfico, n. 42, p. 35-34, Universidade de São Paulo, São Paulo, SP, 1994.

HENDRX GENETCS COMPANY. **AviGuia**.

<http://www.aviguia.com.br/figuracao/figuracao.asp?codemp=2331> (Acesso 25/05/2018)

HAYKIN, S. *Redes neurais: princípios e prática*. Porto Alegre: Bookman, 2001.

IBGE (Instituto Brasileiro de Geografia e Estatística). **Projeção da População do Brasil e das Unidades da Federação**. Disponível na Internet: www.ibge.gov.br/apps/populacao/projecao/ (Acesso em 11 de junho de 2019)

LIU, S. Application of neural networks in multiphase flow through porous media: Predicting capillary pressure and relative permeability curves. **Journal of Petroleum Science and Engineering**. v.180, p.445-455,2019

MAIA, G A R. Avicultura Alternativa: **Carne e Ovos pelo Sistema de Pastejo**. Artigos Técnicos da Sociedade Nacional de Agricultura, Brasília, ano 100, p. 1-6, set. 1997.

MARTINS, T. M.; MARANGON G. P.; COSTA E. A.; SILVEIRA D. B.; CUBAS R.; CAVALLI P. J.; Estimação da altura de plantios florestais de eucalipto por regressão de redes neurais artificiais. **Scientific Jornal**, Curitiba, v. 5 n. 1 p. 153-160, jan. 2020

MORAES, L.D. Evaluation of follicular lymphoid depletion in the Bursa of Fabricius: na alternative methodology using digital image analysis and artificial neural networks. **Pesquisa Veterinária Brasileira**. v.30, p.340-344,2010

NUNES, Osmir J. Pai da ornitopatologia brasileira. Artigo publicado pela Revista Espiral (Ano 2 - n° 5 – out/nov/dez de 2000), um dos órgãos de divulgação do Núcleo José Reis de Divulgação Científica da ECA – Escola de Comunicações e Artes da USP: www.eca.usp.br/nucleos/njr/. (Acesso em 22 de junho de 2019)

ODA C. M.; SEDIYAMA T.; Eder MATSUO E.; NASCIMENTO M.; CRUZ D. C.; Estabilidade e a adaptabilidade de produção de grãos de soja por meio de metodologias tradicionais e redes neurais artificiais. **Scientia Agraria Paranaensis**, Paraná, v. 18, n. 2, abr./jun., p. 117-124, 2019

PINTO, P.R. **Dissertação de Mestrado**: Uso de redes neurais artificiais no gerenciamento de matadouros-frigoríficos de aves e suínos no Sul do Brasil. Porto Alegre, UFRGS, Faculdade de Veterinária, PPGCV, p.76, 2006.

RAMOS J.P.S. Redes Neurais Artificiais na classificação de frutos: cenário bidimensional. **Ciências Agrotécnicas**, 27, 356-362.2003.

RAMIREZ-MORALES, I. Automated early detection of drops in commercial egg production using neural networks. **British Poultry Science**. v.58, p.739-747,2017.

REALI E.H. **Dissertação de Mestrado**. Utilização de inteligência artificial (redes neurais artificiais) no gerenciamento da produção de frangos de corte. 2004 – UFRGS- Universidade Federal do Rio Grande do Sul, Faculdade de Veterinária, programa de Pós-Graduação em Ciências Veterinárias, 2004.

RIBEIRO R.; CASANOVA D.; TEIXEIRA M.; WIRTHB A.; GOMES M. H.; BORGES P.A.; ENEMBRECK F.; Generating action plans for poultry management using artificial neural networks, **Computers and Electronics in Agriculture**, p. 131–140, fev 2019

ROCHA A.C.G.P. **Tese de doutorado**. Utilização de Inteligência Artificial para a Classificação de Patogenicidade de Amostras de *Escherichia coli* Isoladas de frangos de corte. 2006 - UFRGS- Universidade Federal do Rio Grande do Sul, Faculdade de Veterinária, programa de Pós-Graduação em Ciências Veterinárias, Porto Alegre, BRRS, 2006.

ROCHA, D.T. **Dissertação de Mestrado**: Utilização de redes neurais artificiais para a classificação da resistência a antimicrobianos e sua relação com a presença de 38 genes associados a virulência isolados de amostras de *Escherichia coli* provenientes de frangos de corte. Porto Alegre, UFRGS, Faculdade de Veterinária, PPGCV, 49p., 2012.

SALAZAR R.; ROJANO F.; ABRAHAM R.; A Simulation of the Broiler Growth Rate Using Artificial Neural Networks, **Research in Computing Science**, México, pp. 81–90; jun. 2015

SALLE, F.O. **Tese de Doutorado**: Utilização de inteligência artificial (redes neurais artificiais) para a classificação da resistência a antimicrobianos e de comportamento bioquímico de amostras de *Escherichia coli* isoladas de frangos de corte. Porto Alegre, UFRGS, Faculdade de Veterinária, PPGCV, 88p., 2009.

SALLE, F.O. **Dissertação de Mestrado**: Utilização de inteligência artificial (redes neurais artificiais) no gerenciamento do incubatório de uma empresa avícola do sul do Brasil. Porto Alegre, UFRGS, Faculdade de Veterinária, PPGCV, 82p., 2005.

SALLE, C. T. P. CÉ, M. C., SANTOS, C. H. C., GUAHYBA, A. D. S., & NASCIMENTO, V. P. D. **Use of statistical techniques on the interpretation of routine serological data produced by a poultry industry**, In (pp. 130). Vancouver - Canada. 1999b

SALLE, C. T.; GUAHYBA, A. S.; WALD, V. B.; SILVA, A. B.; SALLE, F. O.; FALLAVENA, L. C. B. Uso de Redes Neurais Artificiais para Estimar Parâmetros de Produção de Galinhas Reprodutoras Pesadas em Recria. **Revista Brasileira de Ciência Avícola**, v. 3, p. 257-264, 2001.

SALLE, C. T.; WALD, V. B.; SILVA, A. B.; SALLE, F. O.; NASCIMENTO, V. P. Use of artificiais neurais networks to estimate production variables of broilers in the production phase. **Br Poult.Sci.**, v.44, n. 2, p. 211-217, 2003.

SAVEGNANO, R.P. Comparison of logistic and neural networks models to fit to the egg production curve of White Leghorns hens. **Poultry Science**, v.90, p.705-711, 2011.

SEFEEDPARI, P. Prophesying egg production based on energy consumption using multi-layered adaptive neural fuzzy inference system approach. **Computers and Electronic in Agriculture**, v.131, p.10-19, 2016

SECRETARIA DE ESTADO DA AGRICULTURA E DO ABASTECIMENTO. **Departamento de Economia Rural**. Disponível em: <http://www.agricultura.pr.gov.br/modules/uploads/12mar2015.pdf>. Acesso 20/07 /2018.

SILVA, Leandro N. de; VON ZUBEN, Fernando J. **Redes Neurais Artificiais**. Disponível em: <ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ia006_03/topico5_03.pdf>. Acesso em 15 de agosto de 2019.

SILVA, L.N.C. Dissertação de Mestrado: Análise e Síntese de Estratégias de Aprendizado para Redes Neurais Artificiais. Campinas, Universidade Estadual de Campinas, 248 p., 1998.

SPOHR, A. **Dissertação de Mestrado**: Gerenciamento através de redes neurais artificiais das atividades de produção de reprodutoras pesadas e dos frangos de corte, de um incubatório e de um abatedouro avícola. Porto Alegre, UFRGS, Faculdade de Veterinária, PPGCV, 61 p., 2011.

TEJKOWSKI, T.M. **Dissertação de Mestrado**: Uso de redes neurais artificiais para classificação de patogenicidade de Escherichia coli de origem aviária. Porto Alegre, UFRGS, Faculdade de Veterinária, PPGCV, 64 p., 2013.

UBA (União Brasileira de Avicultura). **Relatório Anual 2017 /2018**. Disponível em na internet: <http://abpa-br.com.br/files/publicacoes/1dae07eab061c11e7985bf2c61.pdf> (Acesso 20/08/2019)

Anexo A- Autorização de Uso e Publicação



Para:
Programa de Pós-graduação em Ciências Veterinárias - UFRGS

Autorização de Uso e Publicação

A empresa Mercoaves Com. Aves Ltda, CNPJ 04.137.827/0001-00 autoriza, na pessoa de seu diretor Gauben Peruzzo, a utilização dos dados zootécnicos de seus lotes de matrizes de aptidão postura comercial na elaboração da dissertação de mestrado "Gerenciamento de índices zootécnicos em lotes de matrizes de postura comercial através do uso de redes neurais artificiais".

O presente trabalho será desenvolvido pelo aluno no PPG-CV da UFRGS Eder Barbosa Oliveira, sendo assim, autorizamos a publicação dos dados em conformidade com o desenvolvimento da dissertação.

Sem mais e certo de sua compreensão!

MERCOAVES COM AVES
CNPJ 04.137.827/0001-00

Diretor

Bom Princípio / RS, 09 de dezembro de 2019.