

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

**GERENCIAMENTO DE ÍNDICES PRODUTIVOS EM LOTES DE POSTURA
COMERCIAL
ATRAVÉS DO USO DE REDES NEURAIAS ARTIFICIAIS**

Dissertação de Mestrado

Luiz Gabriel Barreto de Almeida

PORTO ALEGRE

2020

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

**GERENCIAMENTO DE ÍNDICES PRODUTIVOS EM LOTES DE POSTURA
COMERCIAL
ATRAVÉS DO USO DE REDES NEURAIAS ARTIFICIAIS**

Autor: Luiz Gabriel Barreto de Almeida

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: Hamilton Luiz de Souza Moraes

PORTO ALEGRE

2020

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior-Brasil (CAPES)-Código de Financiamento 001

Almeida, Luiz Gabriel Barreto de
Gerenciamento de índices produtivos em lotes de
postura comercial através do uso de Redes Neurais
Artificiais / Luiz Gabriel Barreto de Almeida. --
2020.
57 f.
Orientador: Hamilton Luiz de Souza Moares.

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. Postura Comercial.
3. Gerenciamento Índices Produtivos. I. Moares,
Hamilton Luiz de Souza, orient. II. Título.

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

Luiz Gabriel Barreto de Almeida

**Gerenciamento de índices produtivos em lotes de postura comercial
através do uso de Redes Neurais Artificiais**

Aprovada em 06 de fevereiro de 2020

APROVADA POR :

Prof. Dr. Hamilton Luiz de Souza Moraes
Orientador e Presidente da Comissão

Prof. Dr. Thales Quedi Furlan
Membro da Comissão

Prof. Dr. Benito Guimarães de Brito
Membro da Comissão

Prof. Dr. Felipe de Oliveira Salle
Membro da Comissão



“Science is Measurement” – Henry Stacy Marks (WEINER,1995)

AGRADECIMENTOS

Agradeço a todos que, no decorrer de minha vida pessoal e profissional, serviram de modelo nos quais me inspirei para percorrer a estrada. Já foi dito que mais importante que o destino é o caminho e para essas pessoas que encontrei no trajeto e que, pelo exemplo, que é a melhor forma de influenciar positivamente alguém, me ajudaram a vencer os obstáculos, a minha eterna gratidão.

À Agro Avícola Filippesen Ltda pela providencial cedência de seus dados de produção, sem os quais seria impossível desenvolver esse trabalho.

Aos meus familiares, aos familiares que a vida me deu, aos meus amigos, aos meus colegas, aos meus mestres, a todos que de uma maneira ou outra foram partícipes nessa jornada meu muito obrigado.

Agradecimento especial à Fabiana, Arthur, Ana Carolina e Lucca, razões de tudo isso.

A vocês todo meu amor.

RESUMO

O presente estudo utilizou Redes Neurais Artificiais (RNAs) elaboradas pelos programas computacionais *NeuroShell®Predictor* e *NeuroShell®Classifier* para avaliar dados zootécnicos de 42 lotes de aves produtoras de ovos comerciais provenientes de uma empresa localizada na Região Serrana do Estado do Rio Grande do Sul. Os dados foram gerados de 2010 a 2018 abrangendo um total de 600.000 poedeiras comerciais. As variáveis objeto desta avaliação foram fase de criação, local de alojamento, linhagem, cor das aves, peso semanal, uniformidade, percentual de produção semanal, ovo/ave alojada, grama/ave/dia, número de aves mortas por semana, percentual de mortalidade semanal, idade em semanas, identidade e saldo de aves.

Os programas identificaram variáveis de entrada para montagem das redes buscando a predição das variáveis chamadas de saída que foram posteriormente validadas. O processo inicial de treinamento das redes utilizou 50% dos dados disponíveis no banco de dados da granja e o restante 50% foi usado para validação das predições realizadas. Os resultados do Coeficiente de Determinação Múltipla nos processos de validação das redes foram os que seguem: rede Aves Mortas Semanal $R^2=0,933$, rede Grama/Ave/Dia $R^2=0,738$, rede Ovo/Ave Alojada $R^2=0,990$, rede Peso Semanal $R^2=0,971$, rede Produção Média Semanal $R^2=0,801$ sendo que todas essas tiveram capacidade de predição. A rede Uniformidade apresentou $R^2=-2,995$ e não obteve sucesso nas previsões. Conclui-se que as Redes Neurais Artificiais são um instrumento de grande capacidade de predição dos dados zootécnicos em Produção de Ovos Comerciais e que a constante qualificação dos dados deste processo produtivo proporcionará avanços no gerenciamento da atividade.

Palavras-chave: Redes Neurais Artificiais, Postura Comercial, Gerenciamento de Dados.

ABSTRACT

The present study used Artificial Neural Networks (RNAs) developed by the computer programs NeuroShell® Predictor and NeuroShell® Classifier to evaluate zootechnical data of 42 flocks of commercial layers from a company located in the State of Rio Grande do Sul. The data were generated from 2010 to 2018 covering a total of 600,000 commercial egg producing birds. The variables object of this evaluation were the breeding phase, place of housing , commercial strain, color of the birds, weekly weight, uniformity, percentage of weekly production, egg / bird housed, grams / bird / day, weekly mortality, percentage of weekly mortality, age in weeks, identity and number of birds. The programs identified input variables for assembling the networks in order to predict the variables called output that were later validated. The initial training process of the networks used 50% of the data available in the farm's database and the remaining 50% was used to validate the predictions made. The results of the Multiple Determination Coefficient in the validation processes of the networks were as follows: weekly mortality $R^2 = 0.933$, gram/ bird/ day $R^2 = 0.738$, egg/bird housed $R^2 = 0.990$, weekly weight $R^2 = 0.971$, percentage of weekly production $R^2 = 0.801$, all of which had predictive capacity. The uniformity presented $R^2 = -2.995$ and was not successful in forecasting. It is concluded that the Artificial Neural Networks are an instrument of great capacity for prediction of the zootechnical data in production of commercial eggs and that the constant qualification of the data of this productive process will provide advances in the management of the activity.

Keywords: Artificial Neural Networks, Commercial Egg Production, Data Management.

LISTA DE TABELAS

Tabela 1 - Treinamento de Rede Neural para Predição da Saída Aves Mortas Semanal	22
Tabela 2 - Contribuição Relativa das Variáveis na Predição da Saída Aves Mortas Semanal	23
Tabela 3 – Validação de Rede Neural para Predição da Saída Aves Mortas Semanal	23
Tabela 4 – Treinamento de Rede Neural para Predição da Saída Grama Ave Dia.....	25
Tabela 5 - Contribuição Relativa das Variáveis na Predição da Saída Grama Ave Dia	25
Tabela 6 – Validação de Rede Neural para Predição da Saída Grama Ave Dia	256
Tabela 7 - Treinamento de Rede Neural para Predição da Saída Ovo Ave Alojada.....	27
Tabela 8 - Contribuição Relativa das Variáveis na Predição da Saída Ovo Ave Alojada	27
Tabela 9 – Validação de Rede Neural para Predição da Saída Ovo Ave Alojada	28
Tabela 10 - Treinamento de Rede Neural para Predição da Saída Peso Semanal	29
Tabela 11 - Contribuição Relativa das Variáveis na Predição da Saída Peso Semanal	29
Tabela 12 – Validação de Rede Neural para Predição da Saída Peso Semanal	30
Tabela 13 - Treinamento de Rede Neural para Predição da Saída Produção Média Semanal.....	31
Tabela 14 - Contribuição Relativa das Variáveis na Predição da Saída Produção Média Semanal	31
Tabela 15 – Validação de Rede Neural para Predição da Saída Produção Média Semanal	32
Tabela 16 – Treinamento de Rede Neural para Predição da Saída Uniformidade.....	33
Tabela 17 - Contribuição Relativa das Variáveis na Predição da Saída Uniformidade.....	33
Tabela 18 - Validação de Rede Neural para Predição da Saída Uniformidade.....	34
Tabela 19 - Estatísticas da Validação de Redes Neurais para Predição das Variáveis de Saída	35

LISTA DE FIGURAS

Figura 1 - Representação de uma Rede Neural Artificial .	20
Figura 2 - Valores Preditos e Reais para Variável de Saída Aves Mortas Semanal	24
Figura 3 - Valores Preditos e Reais para Variável de Saída Grama Ave Dia	26
Figura 4 - Valores Preditos e Reais para Variável de Saída Ovo Ave Alojada	28
Figura 5 - Valores Preditos e Reais para Variável de Saída Peso Semanal	30
Figura 6 - Valores Preditos e Reais para Variável de Saída Produção Média Semanal	32
Figura 7 - Valores Preditos e Reais para Variável de Saída Uniformidade	34

SUMÁRIO

1	INTRODUÇÃO	12
2	REVISÃO BIBLIOGRÁFICA	14
2.1	Conceito e Funcionamento das RNAs.....	14
2.2	Utilidade e Exemplos de Uso das RNAs.....	15
2.3	As RNAs e a Avicultura.....	16
3	MATERIAIS E MÉTODOS	19
3.1	Dados Produtivos.....	19
3.2	Análise Estatística.....	19
3.3	Redes Neurais Artificiais.....	19
4	RESULTADOS	22
5	DISCUSSÃO	35
6	CONCLUSÕES	40
7	REFERÊNCIAS BIBLIOGRÁFICAS	41
8	ANEXO A	46

1 INTRODUÇÃO

Alimentar de forma organizada, eficiente e segura um grupo de indivíduos foi, provavelmente, o primeiro desafio de nossos antepassados assim que se iniciou a presença do homem na Terra. Esse desafio permanece cada dia mais atual já que de uma população mundial estimada em 7,7 bilhões de pessoas (ONU, 2019), em torno de 820 milhões sofre de desnutrição (FAO, 2019) com um incremento aproximado de 5 milhões de pessoas nesta condição em apenas um ano. Na América Latina, a FAO estima haver 7% da população em grau de desnutrição severo, o que permite supor que, na falta de dados atualizados e a despeito de opiniões diversas, existem no Brasil em torno de 14 milhões de famintos, número esse baseado na estimativa populacional de 210 milhões de habitantes (IBGE, 2019).

A produção de alimentos de origem animal embasada em conceitos técnicos remonta dos primórdios da humanidade, sendo a domesticação dos animais de produção ponto fundamental para o desenvolvimento das populações (HARARI, 2017). A produção de proteína animal representa, desde então, uma importante ferramenta de atendimento das necessidades nutricionais destas populações. Dentro de uma gama de produtos de origem animal, a presença dos ovos vem, a cada dia, tomando uma importância maior no cenário brasileiro e mundial.

No Brasil, a importância do consumo de ovos, traduz-se em um aumento significativo de consumo per capita observado nos últimos anos. O brasileiro passou de um consumo de 148 (no ano de 2010) para 192 (em 2017) ovos per capita ano (ABPA, 2018). Embora distante ainda dos países maiores consumidores de ovos como o México com 360 ovos/ano (CHB, 2019) a evolução do consumo e sua já projetada continuidade, representa um desafio ao conjunto de instituições envolvidas na produção de ovos.

Embora os volumes de produção no Brasil estejam ano a ano sendo ampliados, chegando a quase 40 bilhões de unidades de ovos em 2017 (ABPA, 2018), permitir que essa produção possa se expandir dentro de conceitos técnicos, de segurança alimentar e possibilitando que o produtor mantenha viável seu empreendimento, garantindo o futuro da atividade, demandam bem mais que boa vontade e trabalho árduo.

Tornar um processo de produção previsível a ponto de otimizar os recursos a serem disponibilizados para o mesmo, tendo para isso que lutar contra as características intrínsecas de imprevisibilidade da produção animal, pode representar a diferença entre mantê-lo viável e sustentável ou fazê-lo dispendioso e perecível.

Uma forma de se conseguir isso é lançar mão de instrumentos que acompanham a humanidade por séculos e que constituem aspecto crucial da ciência moderna: a observação constante e objetiva e o uso de ferramentas matemáticas para relacionar essas observações (HARARI, 2017).

Segundo Sagan, “Devemos quantificar. Se o que estiver sendo explicado é passível de medição seremos muito mais capazes de discriminar entre as hipóteses concorrentes” (SAGAN, 2006) ou ainda “decisões tomadas sem critérios objetivos não são decisões, são palpites” (SALLE, 2018a).

No caso dos processos produtivos da avicultura uma das ferramentas que vem apresentando resultados significativos para o aprimoramento da identificação de adequados métodos de predição de resultados e índices são as Redes Neurais Artificiais (RNA).

Desde 2001 o Centro Diagnóstico e Pesquisa em Patologia Aviária da Faculdade de Medicina Veterinária da Universidade Federal do Rio Grande do Sul (CPDA-UFRGS), vêm desenvolvendo linha de pesquisa utilizando as RNA nos diversos modelos de produção avícola buscando estabelecer método e ferramentas para mitigar as dificuldades de acompanhamento e gerenciamento destas atividades. No caso específico da produção de postura comercial é ainda mais significativa essa busca por se tratar de um setor parco em estatísticas (DESOUZART, 2019).

O objetivo desta dissertação é buscar estabelecer bases iniciais para o entendimento das possibilidades de utilização desta ferramenta na predição e gerenciamento dos dados zootécnicos na atividade de produção de ovos comerciais com intenção de maximizar os resultados dos lotes de aves alojados e minimizar os custos e percalços no caminho para atingir essa meta.

2 REVISÃO BIBLIOGRÁFICA

2.1 Conceito e Funcionamento das RNAs

As Redes Neurais Artificiais (RNAs) são uma forma diferenciada de trabalhar o processo computacional com inspiração na neurofisiologia humana. Um modelo simplificado de um neurônio humano é organizado em redes que simulam o que encontramos no cérebro humano, e com características inerentes ao mesmo, quais sejam: habilidades de aprendizagem, generalização e abstração (WASSERMAN, 1987).

O processo de aprendizagem da RNA se dá por exemplos e assim a rede tem capacidade de identificar situações posteriores a partir de amostras iniciais com as quais ela promove relações de similaridade (WASSERMAN, 1988).

Para Dytch (1990), o processo pelo qual uma rede neural aprende através do exemplo e gradualmente incorpora em seu conhecimento esse aprendizado, além da capacidade de tolerar dados ambíguos ou mesmo espúrios, permite utilizá-la para lidar com casos desconhecidos. Para ele as redes neurais artificiais, utilizadas em conjunto com outras técnicas de inteligência artificial, são capazes de fornecer ferramentas úteis para o desenvolvimento de sistemas (DYTCH, 1990).

A capacidade de generalização das redes permite que mesmo a partir de dados de entrada com equívocos de geração ou lançamento sejam obtidos resultados coerentes com o buscado na avaliação. Essa característica torna a ferramenta uma mais “natural” interface entre os sistemas e o mundo real (WASSERMAN, 1988).

De forma similar a habilidade de abstração demonstrada pelas RNAs permite que se obtenha, a partir de um processo de aprendizagem com dados corrompidos, respostas como se houvesse uma situação próxima do ideal nesta fase de treinamento. RNAs podem gerar resultados ideais a partir de um grupo de exemplos imperfeitos. (WASSERMAN, 1988).

Para uma melhor compreensão sobre as RNAs podemos usar a definição de Silva (2019) que diz 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. Assim como no sistema nervoso o processamento de informação ocorre em diversas unidades simples conectadas em redes neurais sendo que cada neurônio é capaz de receber estímulos de entrada de diversos outros neurônios e propagar uma única saída de único sentido ou sentido múltiplo (SILVA, 2019).

Como no cérebro humano as Redes Neurais Artificiais apresentam uma organização em lâminas, chamadas também de camadas, sendo que estas camadas apresentam contatos entre si e estão subdivididas em camadas de entrada, camadas intermediárias ou escondidas e camadas de saída. As redes de múltiplas camadas possuem uma ou mais destas camadas intermediárias. A conexão destas camadas se faz pelas sinapses neuronais sendo que a plasticidade sináptica, que é a capacidade das sinapses sofrerem modificações e com isso modularem o processamento das informações constitui a base do processo cognitivo tanto das redes neuronais biológicas como das RNAs. Um sistema de associar pesos com as informações armazenadas pelo neurônio e a adaptação desses pesos aos estímulos do ambiente é como se dá esse processo que permite a RNA trabalhar com as habilidades semelhantes à percepção, raciocínio e memória das redes biológicas (SILVA, 2019).

A capacidade de aprender das RNAs na realidade trata-se da habilidade de se adaptar alterando seu desempenho ao longo do tempo. O tipo de aprendizado é determinado pela técnica empregada no processo de ajustes dos pesos sinápticos. Um conjunto bem determinado destas regras constitui um algoritmo de aprendizagem ou treinamento, sendo que a maneira como o ambiente influencia a rede ela terá um aprendizado supervisionado, não supervisionado ou por reforço (SILVA, 2019).

2.2 Utilidade e Exemplos de Uso das RNAs

As capacidades peculiares das RNA as tornam instrumentos válidos para trabalhos nas mais diversas atividades humanas fornecendo métodos de identificação de tendências e previsões em áreas diametralmente opostas do conhecimento humano como um todo. Em uma rápida pesquisa, realizada em 07 de agosto de 2019, na base de dados científicos WEB

OF SCIENCE foram identificados 293.964 artigos publicados no século XXI tendo como base as RNAs. Estas pesquisas envolvem situações tão díspares quanto identificar risco de isquemia coronariana e a resposta emocional a sons, passando pela avaliação de porosidade em rochas na prospecção de petróleo e a estimativa da fertilidade de solos agriculturáveis.

Em um trabalho para avaliação de risco de isquemia coronariana utilizando RNAs para avaliar as ondas de um eco cardiograma- estas tiveram uma especificidade de 86% e uma sensibilidade de 87% em identificar os quadros de isquemia (MCMAHON, 2008). Kim (2019) demonstrou a habilidade das RNAs para prever respostas emocionais de humanos a sons através da análise de imagens de ressonância magnética funcional de cérebro de indivíduos estimulados por emissões sonoras determinadas.

O ato de estimar a fertilidade de solos passíveis de utilização em agricultura demanda análises que produzem resíduos químicos com potencial de contaminação ambiental. Utilizar as RNAs na avaliação de matéria orgânica de solos produzindo dados acurados destes parâmetros permitiria minimizar estes riscos ambientais (FERNANDES, 2019). Liu (2019) demonstrou que as Redes Neurais Artificiais (RNA) 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.

2.3 As RNAs e a Avicultura

A utilização das RNAs na avaliação dos processos de produção da avicultura moderna já tem registro bastante substancial. As diversas facetas desta produção já foram contempladas por vários trabalhos conduzidos pelo Grupo do CDPA-UFRGS, desde o início dos anos 2000. Na utilização das RNAs em gerenciamento de dados produtivos e índices de sanidade em lotes de matrizes pesadas alojadas em empresa de produção de frangos de corte (GUAHYBA, 2001), passando pela busca de melhores condições de entendimento de situações de produção em um fomento de uma integração de frangos de corte (REALI, 2004), no acompanhamento e validação de predições de dados técnicos e indicadores de sanidade em incubatório (SALLE, 2005), no estabelecimento de bases de condução gerencial de um abatedouro de frangos de corte (PINTO, 2006), em um processo de gerenciamento amplo em uma integração de produção de frangos de corte envolvendo

todos os diversos setores desta integração (SPOHR, 2011). Em todas essas situações relacionadas diretamente ao processo produtivo houve resposta positiva na implementação das Redes .

Da mesma forma o uso da RNAs teve resultado valioso quando estas foram confrontadas com situações envolvendo quadros ligados a sanidade de aves, como por exemplo, uma série de trabalhos realizados com amostras de *Escherichia coli* isoladas de produção aviária, como na predição da resistência antimicrobiana de bactérias isoladas de frango de corte (ROCHA, 2012), na predição e classificação de índice de patogenicidade de bactérias isoladas de frango de corte (ROCHA, 2006), na classificação de patogenicidade de bactérias de origem aviária (TEJKOWSKI, 2013), na classificação de resistência antimicrobiana e de comportamento bioquímico de bactérias isoladas de frango de corte (SALLE, 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 (CARVALHO, 2013). Em todos os trabalhos desenvolvidos dentro do Grupo do CDPA-UFRGS foi possível verificar que as RNAs são plenamente indicadas como ferramentas de auxílio no acompanhamento e na predição de dados gerenciais, zootécnicos e indicadores de sanidade das diversas explorações avícolas.

No caso de produção comercial de ovos para consumo, o uso de RNAs já teve registros buscando estabelecer a eficiência como ferramenta de predição baseando-se em observação de consumo de ração e produção utilizando linhagens distintas de aves de postura comercial alojadas em condições experimentais (AHMAD, 2011) ou na 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 na busca de 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).

Esses trabalhos indicam que a utilização das RNAs em produção de ovos comerciais, pode constituir uma importante capacitação nos métodos de gerenciamento das atividades relacionadas com esse segmento da produção avícola. O objetivo deste trabalho é estabelecer que essa ferramenta pode ser empregada a partir da utilização de dados reais de produção e examinando a luz das RNAs um volume significativo de dados, para realizar previsões e simulações.

3 MATERIAL E MÉTODOS

3.1 Dados Produtivos

Neste estudo foram utilizados dados de 42 lotes de produção de ovos comerciais de uma empresa localizada na Região Serrana do Estado do Rio Grande do Sul, resultantes do processo produtivo da referida empresa entre os anos de 2010 e 2018. Para realização do presente estudo 600.000 poedeiras comerciais tiveram os índices zootécnicos de seus lotes avaliados. As variáveis que foram objeto desta avaliação são as seguintes: fase de criação (recria ou produção), identidade (número que identifica o lote), local de alojamento (galpão onde as aves estão alojadas), linhagem, cor das aves (brancas ou vermelhas), peso semanal, uniformidade semanal, percentual de produção semanal, ovo/ave alojada cumulativo, grama/ave/dia média semanal, número de aves mortas por semana, percentual de mortalidade semanal, peso semanal padrão, percentual de produção semanal padrão, ovo/ave alojada cumulativo padrão, grama/ave/dia padrão semanal.

No total 59000 células de dados foram lançados para a elaboração das RNAs

3.2 Análise Estatística

A estatística descritiva e o cálculo das diferenças entre as médias dos dados foram realizados com o auxílio do programa *SigmaStat Statistical Software* para Windows.

3.3 Redes Neurais Artificiais

Para elaboração das Redes Neurais Artificiais foram utilizados os programas computacionais *NeuroShell[®] Predictor* e *NeuroShell[®] Classifier* desenvolvidos pela empresa Ward Systems Group.

No decorrer da apresentação dos resultados a expressão “entrada” estará relacionada aos parâmetros zootécnicos utilizados como as variáveis escolhidas para os cálculos do modelo de predição. O termo “saída” será empregado para os parâmetros a serem preditos.

A Figura 1 representa esquematicamente uma Rede Neural Artificial com uma camada de entrada, onde são informados os dados a serem usados nas predições, duas camadas ocultas de neurônios nas quais se buscam as relações entre esses dados de entrada e a camada de saída que será constituída pelas predições realizadas pela rede.

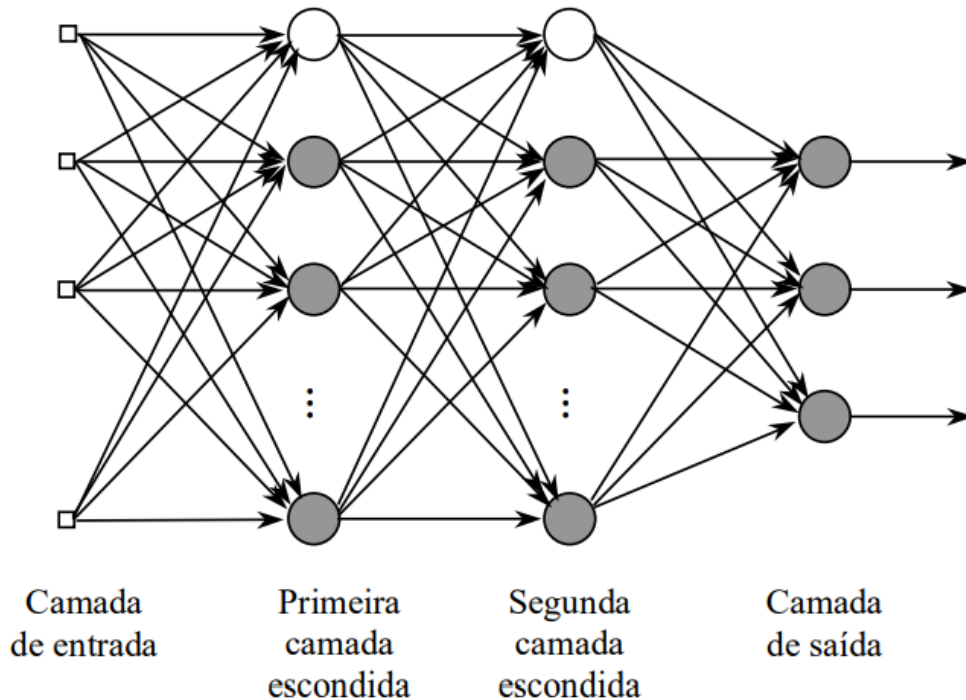


Figura 1 - Representação de uma Rede Neural Artificial - Adaptado de Silva (1998).

A arquitetura da rede demonstra que o processo de aprendizagem da mesma se faz pelas relações construídas entre os dados informados, os resultados destas relações e pelo processo de correção realizada através da comparação entre as predições e os resultados corretos. No processo de aprendizagem da Rede são propostos pesos entre as ligações que relacionam os neurônios de entrada e saída e esses pesos são ajustados em busca de melhores resultados de predição. Os pesos são refinados em busca das respostas mais corretas e o número de neurônios nas camadas intermediárias ocultas será ampliado ,quando necessário, para que essa busca fique adequada ao tipo de banco de dados trabalhado.

Partindo da montagem das redes é possível determinar quais parâmetros tem mais impacto na predição das demais variáveis analisadas. As redes geradas para as variáveis de saída foram comparadas e escolhidas conforme a análise dos valores do Coeficiente de Determinação Múltipla (R^2), do Quadrado Médio do Erro (QME), juntamente com a avaliação de gráficos. O R^2 foi calculado através da fórmula $R^2 = 1 - (SSE/SS_{yy})$, onde $SSE = (\text{valor real} - \text{valor predito})^2$ e $SS_{yy} = (\text{valor real} - \text{média dos valores})^2$. O QME foi calculado como sendo a média dos valores reais menos os valores preditos, elevados à potência 2 [QME = média (valores reais- preditos)²] (SALLE, 2018b).

Para o treinamento das redes foram utilizados 50% dos dados, ou seja 1980 linhas de dados.

Os dados restantes foram objeto da validação dos modelos de predição.

4 RESULTADOS

As Tabelas e Figuras que constituem esse capítulo explicam alguns dos modelos produzidos a partir dos dados zootécnicos de uma empresa produtora de ovos comerciais da Região Serrana do Rio Grande do Sul. Esses dados representam a situação de 42 lotes criados no período de 2010 a 2018 em um total de 600.000 aves. Os valores perfazem 59300 células de informação distribuídas em 3960 linhas de dados. Destas, 1980 linhas foram usadas no processo de treinamento das redes e 1980 no processo de validação das mesmas.

Os resultados são expressos em grupos de Tabelas e Figuras que representam o treinamento e validação da rede com cada saída escolhida para sua montagem. A forma de avaliação de cada rede é baseada nos parâmetros de estatística gerados pelo programa de montagem das mesmas.

Na Tabela 1 estão representadas as características do treinamento da rede para a saída “Aves Mortas Semanal”. O Coeficiente de Determinação Múltipla (R^2) próximo de 1 e a Correlação elevada indicam uma predição de muito boa qualidade. O Quadrado Médio do Erro (QME) e a Raiz do Quadro Médio do Erro (RQME) reduzidos confirmam essa indicação.

Tabela 1 - Treinamento de Rede Neural para Predição da Saída Aves Mortas Semanal

Estatística da Predição	Valores
R^2 -Coeficiente de Determinação Múltipla	0,9866
Erro Médio	5,5619
Correlação	0,9933
QME-Quadrado Médio do Erro	60,4763
RQME- Raiz do Quadrado Médio do Erro	7,7766
Entradas	10

A Tabela 2 demonstra a contribuição de cada variável de entrada na saída “Aves Mortas Semanal”. A soma dos valores das contribuições relativas é 1.

Tabela 2 - Contribuição Relativa das Variáveis na Predição da Saída Aves Mortas Semanal

Entradas	Contribuição Relativa
Idade Semanas	0,275
Local	0,164
Peso Semanal	0,156
Percentual Mortalidade Semanal	0,146
Ovo Ave Alojada	0,123
Uniformidade	0,109
Saldo de Aves	0,015
Produção Média Semanal	0,005
Identidade	0,005
Gramas/Ave/Dia	0,002

A Tabela 3 demonstra as características de validação da rede para a saída “Aves Mortas Semanal”. O Coeficiente de Determinação Múltipla (R^2) e a Correlação elevadas indicam uma validação bastante adequada. O Quadrado Médio do Erro (QME) e a Raiz do Quadro Médio do Erro (RQME) mesmo que mais elevados corroboram essa suposição.

Tabela 3 - Validação de Rede Neural para Predição da Saída Aves Mortas Semanal

Estatística da Validação	Valores
R^2 -Coeficiente de Determinação Múltipla	0,9533
Erro Médio	8,1156
Correlação	0,9781
QME-Quadrado Médio do Erro	256,8893
RQME- Raiz do Quadrado Médio do Erro	16,0059
Entradas	10

A Figura 2 demonstra uma visão completa dos dados preditos e reais usados na validação das previsões para a saída “Aves Mortas Semanal”. A distribuição próxima da linha de tendência mostra tratar-se de uma rede de boa qualidade de predição.

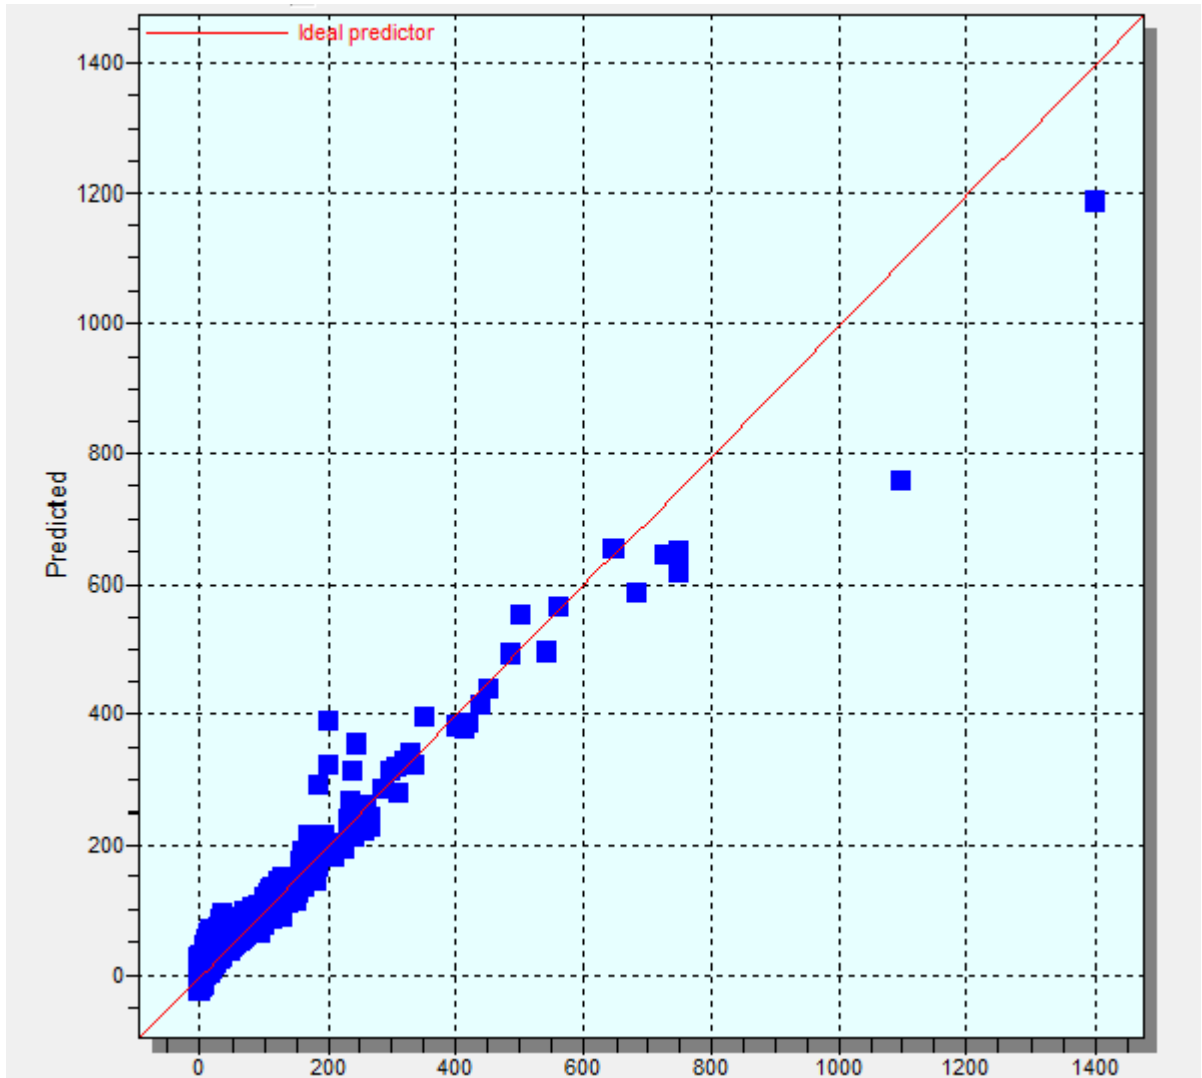


Figura 2 - Valores Preditos e Reais para Variável de Saída Aves Mortas Semanal

A sequência de Tabelas e Figuras que se seguem irá demonstrar os resultados de forma semelhante para as demais redes geradas.

A Tabela 4 demonstra as características do treinamento da rede para a saída “Gramma Ave Dia”. Consideramos que R^2 e a Correlação indicam uma predição de boa qualidade. O

Quadrado Médio do Erro (QME) e a Raiz do Quadro Médio do Erro (RQME), ainda que elevados, permitem confirmar essa indicação, visto os valores absolutos reais variarem de 5 a 130 gramas.

Tabela 4 - Treinamento de Rede Neural para Predição da Saída Grama Ave Dia

Estatística da Predição	Valores
R ² -Coeficiente de Determinação Múltipla	0,7306
Erro Médio	10,4553
Correlação	0,8548
QME-Quadrado Médio do Erro	276,5648
RQME- Raiz do Quadrado Médio do Erro	16,6302
Entradas	9

A Tabela 5 demonstra a contribuição de cada variável de entrada na saída “Gramas Ave Dia”

Tabela 5 - Contribuição Relativa das Variáveis na Predição da Saída Grama Ave Dia

Entradas	Contribuição Relativa
Idade Semanas	0,525
Saldo Aves	0,264
Local	0,087
Identidade	0,085
Uniformidade	0,017
Produção Média Semanal	0,008
Aves Mortas Semanal	0,008
Peso Semanal	0,004
Ovo/Ave Alojada	0,002

A Tabela 6 demonstra as características de validação da rede para a saída “Gramas Ave Dia”. O Coeficiente de Determinação Múltipla (R²) e Correlação altos indicam uma validação de boa qualidade. O Quadrado Médio do Erro (QME) e a Raiz do Quadro Médio do Erro (RQME) mesmo que mais elevados confirmam essa suposição.

Tabela 6 - Validação Rede Neural para Predição da Saída Grama Ave Dia

Estatística da Validação	Valores
R ² -Coeficiente de Determinação Múltipla	0,7382
Erro Médio	10,4834
Correlação	0,8601
QME-Quadrado Médio do Erro	274,56
RQME- Raiz do Quadrado Médio do Erro	16,5698
Entradas	9

A Figura 3 demonstra uma visão completa dos dados preditos e reais usados na validação das previsões para a saída “Gramas Ave Dia”. A distribuição próxima da linha de tendência mostra tratar-se de uma rede de boa qualidade de predição.




Figura 3 - Valores Preditos e Reais para Variável de Saída Grama Ave Dia

A Tabela 7 demonstra as características do treinamento da rede para a saída “Ovo Ave Alojada”. O R^2 e a Correlação elevada indicam uma predição de muito boa qualidade. O Quadrado Médio do Erro (QME) e a Raiz do Quadro Médio do Erro (RQME), ainda que elevados, permitem confirmar essa indicação visto os valores absolutos reais serem de grande variação.

Tabela 7 – Treinamento de Rede Neural para Predição da Saída Ovo Ave Alojada

Estatística da Predição	Valores
R^2 -Coeficiente de Determinação Múltipla	0,982
Erro Médio	9,3789
Correlação	0,946
QME-Quadrado Médio do Erro	140,9137
RQME- Raiz do Quadrado Médio do Erro	11,8707
Entradas	10

A Tabela 8 demonstra a contribuição de cada variável de entrada na saída “Ovo Ave Alojada”

Tabela 8 - Contribuição Relativa das Variáveis na Predição da Saída Ovo Ave Alojada

Entradas	Contribuição Relativa
Uniformidade	0,521
Idade Semanas	0,361
Peso Semanal	0,052
Identidade	0,016
Local	0,013
Saldo de Aves	0,013
Produção Média Semanal	0,013
Percentual Mortalidade Semanal	0,006
Gramas/Ave/Dia	0,003
Aves Mortas Semanal	0,002

A Tabela 9 demonstra as características de validação da rede para a saída “Ovo Ave Alojada”. R^2 e Correlação elevados indicam uma validação de muito boa qualidade. O QME RQME mesmo que mais elevados confirmam essa suposição.

Tabela 9 – Validação de Rede Neural para Predição da Saída Ovo Ave Alojada

Estatística da Validação	Valores
R ² -Coeficiente de Determinação Múltipla	0,9901
Erro Médio	10,3015
Correlação	0,995
QME-Quadrado Médio do Erro	172,2612
RQME- Raiz do Quadrado Médio do Erro	13,1248
Entradas	10

A figura 4 demonstra uma visão completa dos dados preditos e reais sendo que a distribuição muito próxima da linha de tendência mostra que trata-se de uma rede de muito boa qualidade de predição.

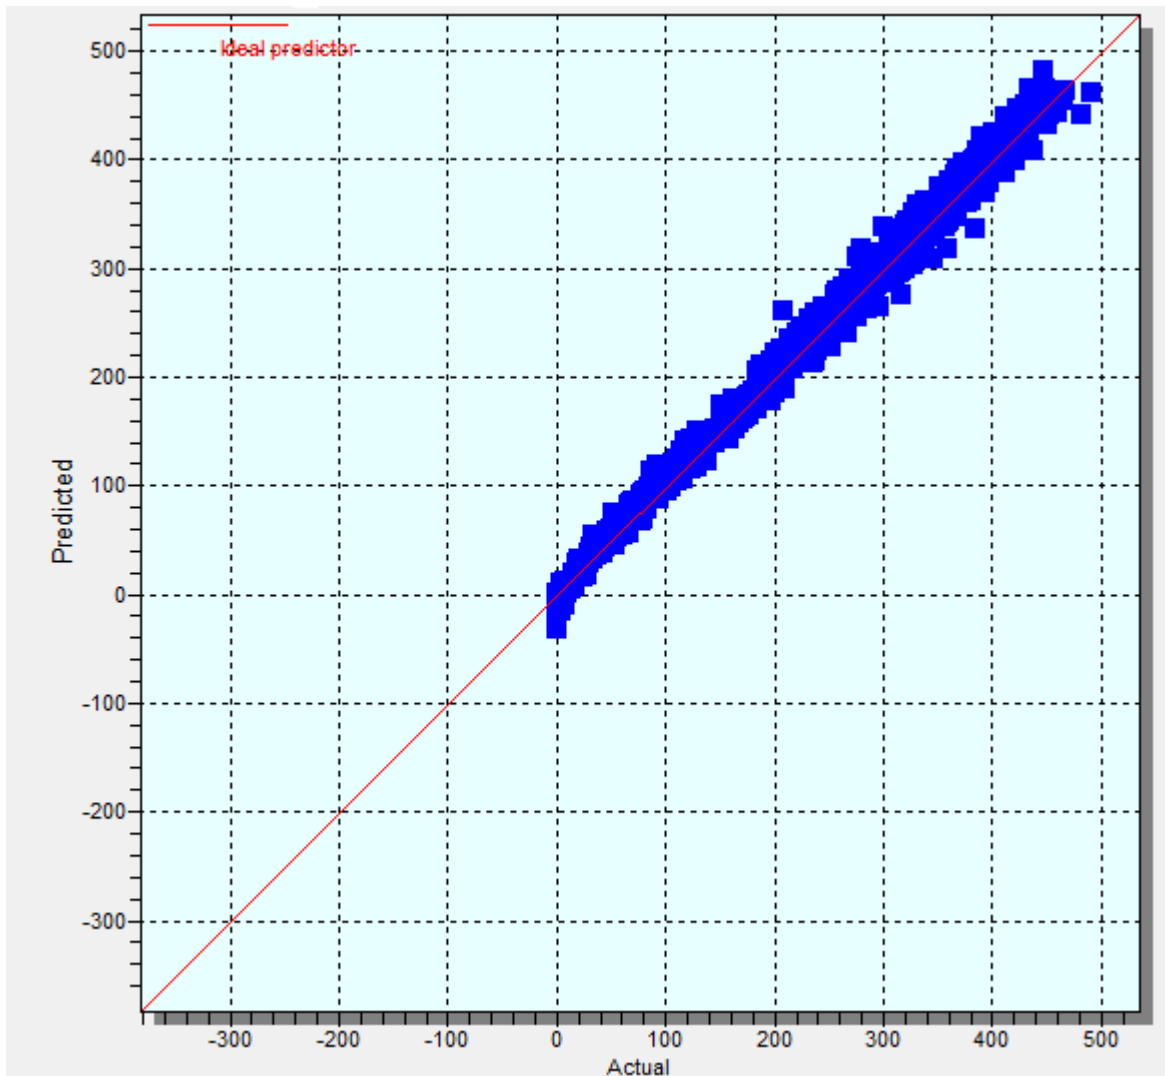


Figura 4 - Valores Preditos e Reais para Variável de Saída Ovo Ave Alojada

A Tabela 10 demonstra as características do treinamento da rede para a saída “Peso Semanal”. O R^2 e a Correlação elevada indicam uma predição de muito boa qualidade. O Quadrado Médio do Erro (QME) e a Raiz do Quadro Médio do Erro (RQME) apresentam valores elevados já que os valores absolutos variam de 30 a 2000 gramas. Ainda sim permitem indicar uma rede de boa qualidade de predição.

Tabela 10 – Treinamento de Rede Neural para Predição da Saída Peso Semanal

Estatística da Predição	Valores
R ² -Coeficiente de Determinação Múltipla	0,9739
Erro Médio	66,8929
Correlação	0,9872
QME-Quadrado Médio do Erro	9582,704
RQME- Raiz do Quadrado Médio do Erro	97,8912
Entradas	5

A Tabela 11 demonstra a contribuição de cada variável de entrada na saída “Peso Semanal”

Tabela 11 - Contribuição Relativa das Variáveis na Predição da Saída Peso Semanal

Entradas	Contribuição Relativa
Idade Semanas	0,552
Saldo Aves	0,312
Identidade	0,054
Uniformidade	0,048
Local	0,035

A Tabela 12 demonstra as características de validação da rede para a saída “Peso Semanal”. O Coeficiente de Determinação Múltipla (R^2) e Correlação elevados indicam uma validação de muito boa qualidade. O Quadrado Médio do Erro (QME) e a Raiz do Quadro Médio do Erro (RQME) mesmo que mais elevados permitem essa indicação.

Tabela 12 – Validação de Rede Neural para Predição da Saída Peso Semanal

Estatística da Validação	Valores
R ² -Coeficiente de Determinação Múltipla	0,9712
Erro Médio	71,8786
Correlação	0,9862
QME-Quadrado Médio do Erro	11154,41
RQME- Raiz do Quadrado Médio do Erro	106,6144
Entradas	5

A Figura 5 demonstra uma visão completa dos dados preditos e reais usados na validação das predições para a saída “Peso Semanal”. A distribuição próxima da linha de tendência mostra tratar-se de uma rede de boa qualidade de predição.




Figura 5 - Valores Preditos e Reais para Variável de Saída Peso Semanal

A Tabela 13 demonstra as características do treinamento da rede para a saída “Produção Média Semanal”. O R^2 e a Correlação alta indicam uma predição de boa qualidade. O Quadrado Médio do Erro (QME) e a Raiz do Quadro Médio do Erro (RQME) permitem também indicar uma rede de boa qualidade de predição.

Tabela 13 - Treinamento de Rede Neural para Predição da Saída Produção Média Semanal

Estatística da Predição	Valores
R ² -Coeficiente de Determinação Múltipla	0,8264
Erro Médio	4,7963
Correlação	0,9115
QME-Quadrado Médio do Erro	65,4153
RQME- Raiz do Quadrado Médio do Erro	8,0879
Entradas	8

A Tabela 14 demonstra a contribuição de cada variável de entrada na saída “Produção Média Semanal”

Tabela 14 - Contribuição Relativa das Variáveis na Predição da Saída Produção Média Semanal

Entradas	Contribuição Relativa
Idade Semanas	0,382
Ovo Ave Alojada	0,382
Saldo Aves	0,090
Identidade	0,046
Local	0,039
Peso Semanal	0,037
Gramas/Ave/Dia	0,018
Percentual Mortalidade Semanal	0,004

A Tabela 15 demonstra as características de validação da rede para a saída “Produção Média Semanal”. O Coeficiente de Determinação Múltipla (R^2) e Correlação altos indicam uma validação de boa qualidade. O Quadrado Médio do Erro (QME) e a Raiz do Quadro Médio do Erro (RQME) permitem que se confirme essa indicação.

Tabela 15 - Validação Rede Neural para Predição da Saída Produção Média Semanal

Estatística da Validação	Valores
R ² -Coeficiente de Determinação Múltipla	0,8015
Erro Médio	4,9715
Correlação	0,8974
QME-Quadrado Médio do Erro	72,6067
RQME- Raiz do Quadrado Médio do Erro	8,5209
Entradas	8

A Figura 6 demonstra uma visão completa dos dados preditos e reais usados na validação das predições para a saída “Produção Média Semanal”. A distribuição relativamente próxima da linha de tendência mostra tratar-se de uma rede de boa qualidade de predição.

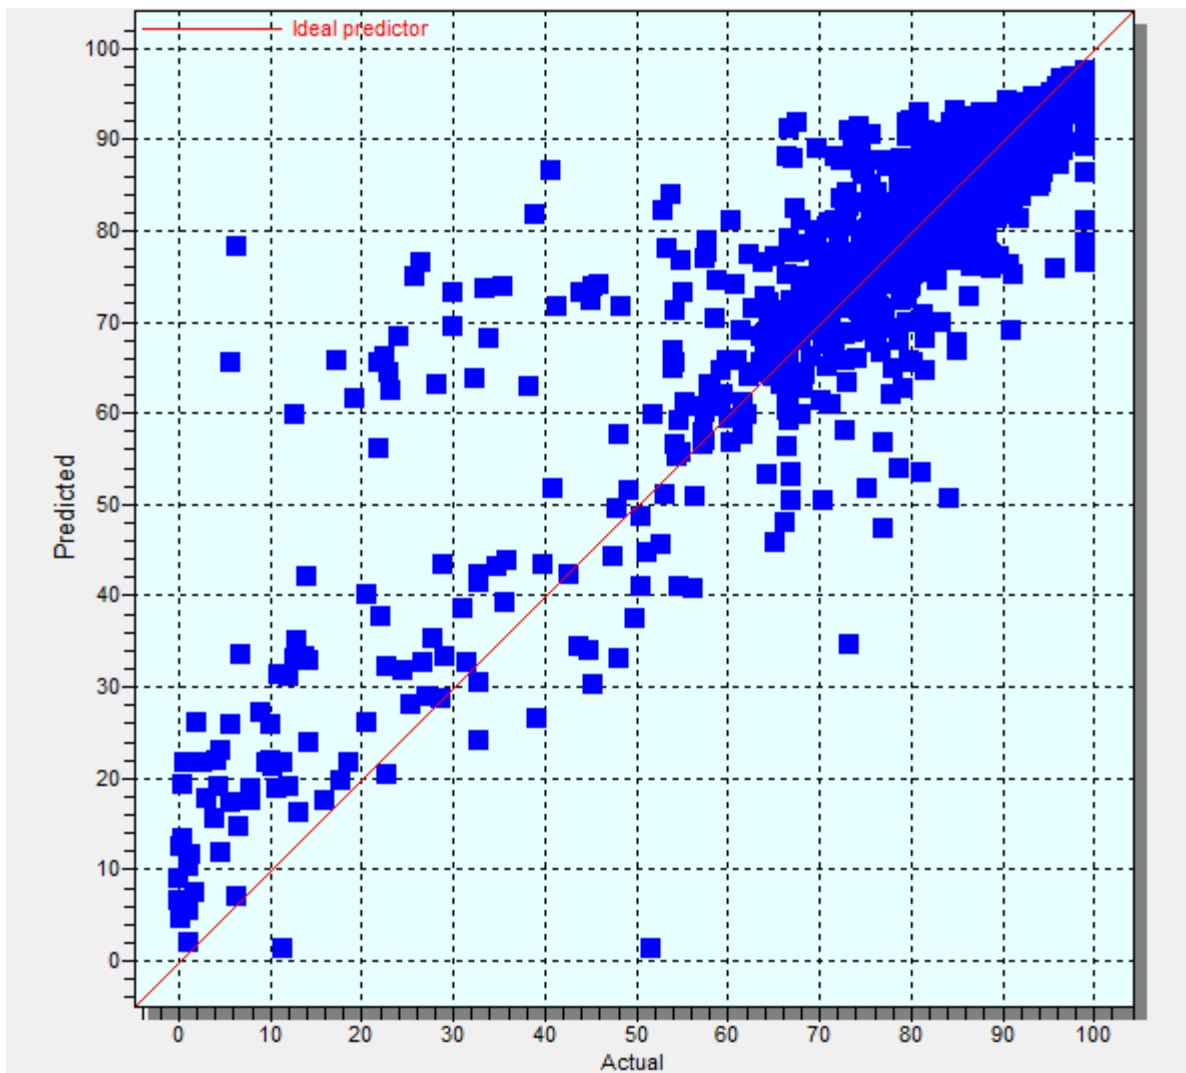


Figura 6 - Valores Preditos e Reais para Variável de Saída Produção Média Semanal

A Tabela 16 demonstra as características do treinamento da rede para a saída “Uniformidade”. O R^2 e a Correlação alta indicam uma predição de boa qualidade. O Quadrado Médio do Erro (QME) e a Raiz do Quadro Médio do Erro (RQME) permitem também indicar uma rede de boa qualidade de predição.

Tabela 16 – Treinamento de Rede Neural para Predição da Saída Uniformidade

Estatística da Predição	Valores
R^2 -Coeficiente de Determinação Múltipla	0,7428
Erro Médio	3,4059
Correlação	0,8618
QME-Quadrado Médio do Erro	23,9112
RQME- Raiz do Quadrado Médio do Erro	4,8899
Entradas	8

A Tabela 17 demonstra a contribuição de cada variável de entrada na saída “Uniformidade”.

Tabela 17 - Contribuição Relativa das Variáveis na Predição da Saída Uniformidade

Entradas	Contribuição Relativa
Idade Semanas	0,379
Peso Semanal	0,35
Aves Mortas Semanal	0,115
Percentual Mortalidade Semanal	0,11
Saldo Aves	0,018
Identidade	0,013
Gramas/Ave/Dia	0,009
Local	0,006

A Tabela 18 demonstra as características de validação da rede para a saída “Uniformidade”. Os valores do Coeficiente de Determinação Múltipla (R^2) e Correlação indicam uma validação inadequada. O Quadrado Médio do Erro (QME) e a Raiz do Quadro Médio do Erro (RQME) permitem que se confirme essa indicação.

Tabela 18 - Validação de Rede Neural para Predição da Saída Uniformidade

Estatística da Validação	Valores
R ² -Coeficiente de Determinação Múltipla	-2,9952
Erro Médio	11,1231
Correlação	0,1763
QME-Quadrado Médio do Erro	431,8232
RQME- Raiz do Quadrado Médio do Erro	20,7803
Entradas	8

A Figura 7 demonstra uma visão dos dados preditos e reais usados na validação das predições para a saída “Uniformidade”. A validação da rede foi impossível de se realizar pela insuficiência de dados lançados. Isso será objeto de comentários na discussão deste trabalho.




Figura 7 - Valores Preditos e Reais para Variável de Saída Uniformidade

5 DISCUSSÃO

Como dito no início da presente dissertação o objetivo deste trabalho foi avaliar a capacidade das RNAs na predição de parâmetros zootécnicos em produção de ovos comerciais a partir da utilização de dados reais, examinando um volume significativo de dados, validando esse instrumento para as diversas características avaliadas. Os resultados obtidos nos permitem afirmar que esta capacidade pode ser considerada adequada e que o processo de avaliação destes dados seria aprimorado se fossem utilizadas as RNAs como rotina no trabalho dos profissionais ligados a atividade de produção de ovos comerciais.

A tabela 19 sumariza as informações estatísticas das validações das redes apresentadas e servirá de guia para as discussões que seguem.

Tabela 19 - Estatísticas da Validação de Redes Neurais para Predição das Variáveis de Saída

Variável de Saída	R ²	QME	Número de Entradas
Aves Mortas Semanal	0,9533	256,18	10
Gramma Ave Dia	0,7382	274,56	9
Ovo Ave Alojada	0,9901	172,26	10
Peso Semanal	0,9712	11154,41	5
Produção Média Semanal	0,8015	72,60	8
Uniformidade	-2,9952	431,82	8

R²-Coeficiente de Determinação Múltipla

QME-Quadrado Médio do Erro

Para R² (Coeficiente de Determinação Múltipla) resultados ao se aproximarem do valor 1 indicam validação de melhor qualidade, ao se distanciarem deste valor tem sua qualidade diminuída. Salle (2019) comenta que valores de R² acima de 0,70, nos processos de treinamento das RNAs, indicam possíveis redes de qualidade para predição.

Ao selecionarmos as RNAs para constarem neste trabalho, buscamos modelos que permitissem discutir os diversos aspectos na estruturação e qualificação das mesmas. Importante ressaltar que todos os parâmetros zootécnicos presentes nas linhas de dados dos

diversos lotes avaliados podem ser elencados como variáveis de saída, restando ao processo de modulação das RNAs verificar a qualificação das mesmas.

No caso da variável de saída “Aves Mortas Semanal” o R^2 do processo de treinamento, que consta na Tabela 1, no valor de 0,9866, indica que a rede deveria ser de muito boa qualidade para predição. As características de entrada mais relevantes, dado apresentado na Tabela 2, foram Idade em Semanas, Local e Peso Semanal. Chama atenção o fato de que a variável “Local” (aviário onde o lote está alojado) seja um dos principais dados, pois vem a corroborar que a observação prática de que, para mortalidade, as condições estruturais e de manejo nas granjas são de grande importância. Cabe também ressaltar que outras informações que deveriam ser relevantes para a predição deste parâmetro em particular, como temperatura ambiente e valores de monitoria sorológica não estavam disponíveis. É possível afirmar que estando estes, e outros dados, disponíveis a contribuição relativa dos parâmetros de entrada poderia ter sido diferente dos apresentados. Na validação da RNA o valor de R^2 de 0,9533, como aparece na Tabela 19, confirma ser uma rede de ótima qualidade para predição de “Aves Mortas Semanal”. Em aves matrizes pesadas Guahyba (2001) encontrou um $R^2=0,924$ para a rede que predizia mortalidade de fêmeas. O muito bom resultado encontrado no presente trabalho não invalida a hipótese de que um banco de dados que disponibilizasse outras informações poderia promover uma qualidade ainda superior na predição. De todo modo fica facilmente visualizado na Figura 2 que a capacidade de predição da RNA para a saída “Aves Mortas Semanal” é de muito boa qualidade, já que a distribuição gráfica dos dados previstos em comparação aos dados reais, com os pontos muito próximos da linha de tendência do gráfico, é claramente verificada.

Para variável de saída “Gramas Ave Dia” a Tabela 4 apresenta o valor de R^2 de 0,7306 indicando que, ainda que não esperemos uma rede de muito boa qualidade para predição, mesmo assim deveria ser adequada para essa situação. As contribuições relativas mais relevantes, dado apresentado na Tabela 5, seriam Idade em Semanas, Saldo de Aves e Local. Certamente há uma relação estreita entre o consumo de ração e a idade das aves e isso aparece claramente no treinamento da RNA (em um valor em que o total é 1 a Idade em Semanas tem valor de 0,525). Na validação da RNA o valor de R^2 de 0,7382, como

aparece na Tabela 19, confirma ser a rede adequada para predição da saída “Grama Ave Dia”. Como elemento importante na discussão deste resultado em particular é fundamental comentar que os lotes utilizados no treinamento e na validação das RNAs não distinguem aves brancas e vermelhas, que possuem claramente consumo de ração distintos, e que devem ser causa de importante fração dos erros cometidos na predição.

Assim sendo, na constituição de redes para predição mais acuradas para a saída Grama Ave Dia a segregação dos lotes de treinamento em duas classes para aves de cores distintas parece ser um pressuposto interessante. A capacidade relativa de predição pode ser observada na Figura 3 que mostra, que, a despeito daquilo comentado anteriormente, há uma adequada predição para a saída Grama Ave Dia.

A saída “Ovo Ave Alojada”, representada na Tabela 7, produziu uma rede que apresenta o valor de R^2 de 0,982, para a predição, que nos permite imaginar uma rede com grande capacidade de acerto. As entradas que se mostraram mais importantes, dado apresentado na Tabela 8, foram Uniformidade, Idade em Semanas e Peso Semanal. A presença da Uniformidade nesta lista das contribuições mais relevantes tem relação lógica se pensarmos na avaliação zootécnica de dados de recria e produção, mas no caso específico do banco de dados disponível, tem um quê de surpresa devido ao pequeno número de lançamentos deste parâmetro. Essa discussão será aprofundada mais adiante. Na validação da RNA o valor de $R^2= 0,9901$, como aparece na Tabela 19, confirma ser a rede muito adequada para predição da saída “Ovo Ave Alojada”.

Fundamental ressaltar que o uso de uma ferramenta com tamanho grau de capacidade de predizer o parâmetro que expressa de forma mais ampla a produção de ovos dos lotes é de grande valia na projeção do futuro das granjas de postura comercial e pode ser o diferencial entre o sucesso e o fracasso na atividade. A capacidade de predição, que pode ser observada na Figura 4, fica clara ao se verificar a distribuição dos pontos preditos comparada aos dados reais.

No caso da variável de saída “Peso Semanal” o R^2 do processo de treinamento, que consta na Tabela 10, no valor de 0,9739 indica que a rede deverá ser de muito boa qualidade para predição. As características de entrada mais relevantes, dado apresentado na Tabela 11, seriam Idade em Semanas, Saldo de Ave e Identidade. Novamente é interessante notar que

existe uma relação lógica entre a entrada mais significativa (Idade) e a saída proposta (Peso Semanal). Chama atenção também um Erro Médio aparentemente alto (66,89) mas devemos lembrar que os valores absolutos deste índice variam de 30 a 2073 gramas . Na validação da RNA o valor de R^2 de 0,9712, como aparece na Tabela 19, confirma ser a mesma rede de muito boa qualidade para predição do Peso Semanal. Este resultado guarda semelhança com o que Spohr (2011) relata para a predição de peso em frangos de corte cujo $R^2=0,971$. No caso da validação para “Peso Semanal” também é importante ressaltar que lotes da aves brancas e vermelhas foram tratados conjuntamente e que a diferença de peso entre essas duas classes, embora importante no aspecto zootécnico não impactou a capacidade de predição da rede. Na Figura 5 fica clara que a capacidade de predição da RNA para a saída Peso Semanal é de muito boa qualidade já que a proximidade da distribuição gráfica dos dados previstos em comparação aos dados reais é claramente verificada.

Para a variável de saída “Produção Média Semanal” o R^2 do processo de treinamento, como está apresentado na Tabela 13, tem como valor 0,8264 , sinalizando que a rede deverá ter boa qualidade para predição. As contribuições mais relevantes como parâmetros de entrada, vide a Tabela 14, seriam Idade em Semanas, Ovo Ave Alojada e Saldo de Aves. Na realidade, Idade em Semanas e Ovo Ave Alojada tem a mesma contribuição na montagem da rede e, mais uma vez, há uma relação lógica entre as entradas mais significativas e a saída avaliada. O valor de R^2 para a validação da rede é de 0,8015, como aparece na Tabela 19, confirmando que a rede construída para a saída Produção Média Semanal é de boa qualidade de predição. Este resultado está acima do encontrado em Ahmad (2011) cujo $R^2 =0,715$ foi determinado para predição de produção de ovos. Na Figura 6 fica demonstrado que a capacidade de predição da RNA para a saída Produção Média Semanal é de boa qualidade, ainda que a distribuição dos pontos relativos à predição versus realidade apresente certa dispersão . Situações como encerramento de lotes em idades distintas, momentos de stress que não estão avaliados nas informações presentes no Banco de Dados, época de ano que lotes iniciaram produção, além das variações de período de luz natural e artificial e que também não estão informados no Banco de Dados, podem ajudar a explicar essa situação de predição adequada, mas diferente de outras redes.

Observando a rede para saída “Uniformidade”, o R^2 do processo de treinamento, presente na Tabela 16, tem como valor 0,7428 , permitindo supor que se tratará de uma rede de boa qualidade de predição. Neste caso, também existe uma lógica zootécnica nas contribuições mais expressivas nas entradas visto, como está na tabela 17, serem Idade em Semanas, Peso Semanal e Aves Mortas Semanal as mais representativas. Porém, o processo de validação gerou um R^2 de valor negativo, como aparece na Tabela 19, desmentido o pressuposto e indicando ser a rede construída para a saída Uniformidade inadequada para a predição. No entanto, a observação da Figura 7 permite dizer que, antes de se concluir pela inadequação da rede, poderíamos responsabilizar o Banco de Dados já que, para esse índice zootécnico, houve poucos lançamentos e acabou restando insuficiente número de lançamentos para validar as predições. Em não havendo dados suficientes para cotejar as predições com valores reais usado na validação não houve como validar corretamente a rede produzida.

Essa situação nos permite afirmar que, a despeito da característica inerente das RNAs de produzir saídas adequadas com informações muitas vezes insuficientes, ainda sim um Banco de Dados mais completo facilitaria a utilização da ferramenta. Adicionar informações sobre estrutura física, ambiente, modelo de criação, classificação de ovos, e dados referentes à sanidade, como vacinações, sorologias, análises laboratoriais seriam passos para qualificar a resposta buscada. Na maioria das situações essas informações, embora fazendo parte da rotina das granjas, acabam sendo relegadas a relatórios aos quais, muitas vezes, não se dá a devida importância, possivelmente por não se constituírem, por si só, em informações com poder decisório. O uso das RNAs em um banco de dados robusto e organizado poderia demarcar a diferença entre um repositório de números sem valia ou um histórico genuíno da empresa que mostrará o caminho a seguir.

6 CONCLUSÕES

1. As Redes Neurais Artificiais foram capazes de prever dados zootécnicos e gerenciais em lotes de Postura Comercial.
2. Mesmo com insuficiência de dados anotados em alguns acompanhamentos dos lotes de produção de ovos comerciais, há resposta correta na utilização das RNAs no gerenciamento destes dados, ainda que algumas redes possam se mostrar inadequadas.
3. A presença de bancos de dados corretamente apontados irá representar maior qualificação na predição das RNAs
4. Predições adequadas possibilitam tornar mais viável a manutenção dos processos produtivos de postura comercial

7 REFERÊNCIAS BIBLIOGRÁFICAS

- ABPA (Associação Brasileira de Proteína Animal). **Relatório Anual de 2018**. Disponível na Internet: www.abpa-br.com.br/storage/files/relatorio-anual-2018.pdf (Acesso em 01 de agosto de 2019)
- AHMAD, H.A. Egg production forecasting: Determining efficient modeling approaches. **Journal of Applied Poultry Research**. v.20, p.463-473,2011.
- CARVALHO, D. **Dissertação de Mestrado**: Avaliação da Perda Linfocitária do Timo de Frangos de Corte Utilizando Sistema de Análise Digital de Depleção Linfóide (ADDL). Porto Alegre, UFRGS, Faculdade de Veterinária, PPGCV, 74p.,2013.
- CHB (Certified Humane Brasil). **México lidera consumo de ovos**. Disponível na internet: <https://certifiedhumanebrasil.org/mexico-lidera-consumo-de-ovos> (Acesso em 01 de agosto 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.
- DESOUZART.O. **Avicultura de Postura do Brasil: Cenário Atual e Onde Podemos Chegar**.Palestra proferida no SIAVS - Salão Internacional de Avicultura e Suinocultura. 2019.Disponível na internet: [www.siavs.com.br>congresso](http://www.siavs.com.br/congresso)
- FAO (Food and Agriculture Organization-ONU). **The State of Food Security and Nutrition in the World-2019**. Disponível na Internet: www.fao.org/3/ca5162en/ca5162en.pdf (Acesso em 01 de agosto de 2019)
- 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.

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.

HARARI, Y.N. **Sapiens- Uma breve história da humanidade**. 19 eds. L&PM,261 p.,2017

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 01 de agosto de 2019)

KIM, H.C. Deep neural network predicts emotional responses of the human brain from functional magnetic resonance imaging. **Neuroimage**. v.186, p.607-627,2019

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

MACMAHON,E.M.Classification of acute myocardial ischemia by artificial neural network using echocardiographic strain waveforms . **Computers in Biology and Medicine**. v.38, p.416-424,2008

MORAES, L.D. Evaluation of follicular lymphoid depletion in the Bursa of Fabricius: an alternative methodology using digital image analysis and artificial neural networks .

Pesquisa Veterinária Brasileira. v.30, p.340-344,2010

ONU (Organização das Nações Unidas). **World Population Prospects 2019.** Disponível na Internet: [https:// population.un.org/wpp/Download/Standard/Population/](https://population.un.org/wpp/Download/Standard/Population/) (Acesso em 01 de agosto de 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.

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. Porto Alegre, UFRGS, Faculdade de Veterinária, PPGCV,127p.,2004.

ROCHA, A.C.G.P. **Tese de Doutorado:** Utilização de inteligência artificial (redes neurais artificiais) para a classificação de patogenicidade de amostras de *Escherichia coli* isoladas de frangos de corte. Porto Alegre, UFRGS, Faculdade de Veterinária, PPGCV, 115p, 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.

SAGAN, C. **O Mundo Assombrado Pelos Demônios.** 1 ed. Companhia das Letras, 509 p., 2006

SALLE, C.T.P. Veterinarians are paid to make decisions. **Appro. Poultry Dairy and Vet. Science**, v.3,2018a

SALLE, C.T.P. Inteligência Artificial: O Futuro da Produção Avícola. **Avicultura Industrial**, v.7, p.38-42, 2018b

SALLE, C.T.P. Comunicação Pessoal, 2019.

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, 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.

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.

SILVA, L. N. de; VON ZUBEN, F. J. **Redes Neurais Artificiais**. Disponível na internet 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 do 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.

WASSERMAN, P.D. Neural Networks.1.What are they and why is everybody so interested in them now. **IEEE Intelligent Systems and Their Applications**, v.2, p.10-12,1987

WASSERMAN, P.D. Neural Networks.2. What are they and why is everybody so interested in them now. **IEEE Intelligent Systems and Their Applications**, v.3, p.10-15,1988

WEINER, J. **O Bico do Tentilhão**. 1ed. Rocco, 345 p.1995.

8. ANEXO A


Autorização de Uso e Publicação

A Agro Avícola Filippesen Ltda autoriza, na pessoa de seu diretor Carlos Raul Filippesen, a utilização dos dados zootécnicos de seus lotes de aves de postura comercial na elaboração da Dissertação de Mestrado:

“Gerenciamento de índices produtivos em lotes de postura comercial através do uso de Redes Neurais Artificiais”

A referida dissertação será desenvolvida pelo aluno do PPG-CV da UFRGS Luiz Gabriel Barreto de Almeida, ficando também autorizada a publicação dos dados em conformidade com o desenvolvimento da dissertação.

Os dados foram disponibilizados ao autor da dissertação com a anuência dos proprietários da empresa.



Carlos Raul Filippesen



Morro Reuter, 29 de outubro de 2018