

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE DE VETERINÁRIA**

**Potencial de aplicação de redes neurais artificiais na gestão de empresas avícolas: uma
simulação a partir da cadeia de produção de frango de corte**

Elisar Camilotti

PORTO ALEGRE

2019/2

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE DE VETERINÁRIA**

Potencial de aplicação de redes neurais artificiais na gestão de empresas avícolas: uma simulação a partir da cadeia de produção de frango de corte

Autor: Elisar Camilotti

Trabalho apresentado à Faculdade de Veterinária como requisito parcial para a obtenção da graduação em Medicina Veterinária

Orientador: Prof. Dr. Carlos Tadeu Pippi Salle

PORTO ALEGRE

2019/2

Elisar Camilotti

Potencial de aplicação de redes neurais artificiais na gestão de empresas avícolas: uma simulação a partir da cadeia de produção de frango de corte

Aprovado em 12 DEZ 2019.

APROVADO POR

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

Prof. Dr. Rafael Ulguim
Membro da Comissão

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

AGRADECIMENTOS

A construção deste Trabalho de Conclusão de Curso contou com o apoio de diversas pessoas, às quais sou muito grato. Correndo o risco de pecar por omissão, agradeço em especial:

À minha família, meus queridos pais Juscelino e Justina e meus irmãos Eliseu e Gustavo, que compreenderam minhas ausências, que me apoiaram e não mediram esforços para que eu alcançasse meus objetivos pessoais e profissionais.

À minha companheira de vida Aline, que compartilhou comigo todas as etapas desta longa trajetória acadêmica. Sempre foi meu porto seguro, a minha melhor amiga para todos os momentos. É o meu grande amor. Suas palavras de incentivo sempre me deixavam mais forte para seguir adiante. Fica aqui toda a minha consideração por sua atenção comigo. O que fizestes por mim não tem valor que pague. Amo demais você, Aline.

Ao meu eterno orientador de TCC, amigo e grande mestre Prof. Tadeu. Uma das pessoas mais incríveis que conheci ao longo da vida. Profissional que nunca está satisfeito com o que conquista, não se acomoda, luta incessantemente para fazer a diferença. Sabes que és minha referência. Sinto enorme gratidão por tudo que me proporcionastes, sendo aquele que abriu as portas da veterinária em minha vida quando me aceitou como estagiário no CDPA. Obrigado por me deixar participar do seu exército e lutar em suas batalhas. Sentirei falta dos seus conselhos.

Ao meu coorientador, amigo e parceiro professor Hamilton. Pessoa de fácil trato, acessível, de boa conversa e de grandes ensinamentos. Veterinário de mão cheia, nunca cansou de me mostrar do que um aluno precisava para se tornar um profissional de sucesso. Ficarão na memória nossos momentos compartilhados. Sentirei saudades da sua lealdade e companhia.

Aos professores da Faculdade de Veterinária da UFRGS, pelos ensinamentos e experiências compartilhadas, por todo o incentivo e instigações acadêmicas, científicas e profissionais.

Aos colegas, estagiários e demais professores do Centro de Diagnóstico e Pesquisa em Patologia Aviária (CDPA/UFRGS), pela colaboração e disposição em todo o processo de ensino e pesquisa que desenvolvi nos últimos anos.

Aos muitos amigos da FAVET, em especial a turma 2015/1, pela amizade, pelos momentos compartilhados e pelo aprendizado acadêmico, pessoal e profissional construídos durante a graduação.

RESUMO

O crescimento da produção avícola no Brasil e no mundo tem sido constante, pois a aceitação da carne de frango por quase todas as culturas e religiões assegura esse aumento. Embora conhecida como a proteína animal mais eficiente do mundo, ainda há ampla margem para crescimento e desenvolvimento do setor avícola. A mesma avicultura que faz uso de equipamentos modernos e serviços atualizados, ainda toma decisões a despeito de aspectos produtivos baseada em critérios subjetivos. Com o crescente desenvolvimento de novas tecnologias da informação, o quadro que se impõe no momento é o da adoção de ferramentas de gestão que incorporem estas inovações. Dentre estas se destaca a modelagem matemática por meio de redes neurais artificiais (RNA, inteligência artificial). Projetados através de um processo de aprendizagem baseado em casos previamente resolvidos (experiências passadas), os modelos de RNA têm poder de reconhecer padrões e prever cenários complexos (de relação não linear). Dentro deste contexto, o presente estudo teve como objetivo avaliar a capacidade de modelos de RNA em prever o valor de indicadores de produção e o potencial impacto econômico (positivo ou negativo) gerado a partir da inter-relação das variáveis que compõem os diferentes segmentos da cadeia de produção da carne de frango (reprodutoras pesadas, incubatório, frango de corte e matadouro-frigorífico). A partir da base de dados de uma empresa avícola que contemplava os registros de 2191 lotes de frango de corte e 40 variáveis, quatro modelos preditivos de RNA foram construídos para as variáveis de maior interesse no estudo: eclosão vendável (1), peso do frango ao final da quinta semana (2), condenação parcial (3) e condenação total de carcaças (4). Com os modelos ajustados, 53 cenários produtivos, combinando ganhos ou perdas de desempenho das variáveis, foram simulados e comparados. Pelos valores preditos foi possível verificar o potencial efeito de alguns parâmetros de produção sobre as variáveis de interesse: (1) - linhagem, tipo de ovo, marca de incubadora e período de estoque dos ovos; (2) - linhagem, sexo e peso do frango na primeira, segunda, terceira e quarta semanas de criação; (3) – sexo, peso de pinto e peso do frango na segunda e terceira semanas de criação; e, (4) – sexo, tipo de pinto, linhagem, taxa de mortalidade na primeira, segunda e terceira semanas e peso do frango na segunda semana de criação. Projeções de desempenho produtivo e econômico foram comparadas com aqueles cenários julgados normais (esperados ou médios) no contexto da série histórica de dados disponível. Considerando ciclos de produção de um milhão de aves, as estimativas do impacto econômico dos diferentes cenários demonstraram haver uma janela de oportunidade de ganho ou perda financeira que pode superar um milhão de reais por ciclo. Além de possibilitar a

predição dos valores de parâmetros de produção importantes dentro do sistema de integração avícola, os modelos de RNA gerados permitiram a realização de simulações de cenários produtivos. Sendo assim, esta ferramenta deve ser incorporada à gestão da produção, pois fornece projeções precisas e objetivas sobre fenômenos de ampla ocorrência no contexto da avicultura industrial.

Palavras-chave: redes neurais artificiais, avicultura, predição, impacto econômico

ABSTRACT

The growth of poultry production in Brazil worldwide has been steady, and also the acceptance of chicken meat by almost all cultures and religions ensures this increase. Although known as the most efficient animal protein in the world, there is still an ample scope for the growth and the development in the poultry sector. The same poultry industry that uses modern equipment and up-to-date services still makes decisions regarding productive aspects based on subjective criteria. With the growing development of new information technologies the current framework is adopting management tools that incorporate these innovations. Among these stand out the mathematical modeling through artificial neural networks (RNA, artificial intelligence). Designed through a learning process based on previously solved cases (past experiences), RNA models have the power to recognize patterns and to predict complex scenarios (nonlinear relationship). Within this context, the present study is aimed to evaluate the ability of RNA models in order to predict the value of production indicators and the potential economic impact (positive or negative) generated from the interrelationship of the variables which make up different segments of chicken meat production chain (breeders, hatchery, broiler and slaughterhouse). From some database of a poultry company that included the records of 2191 broiler flocks and 40 variables, four predictive RNA models were constructed by the variables greatest interest in the study: salable hatching (1), chicken weight at the end of the fifth week (2), partial condemnation (3) and total carcass condemnation (4). With the adjusted models, 53 production scenarios, combining performance gains or losses of the variables, were simulated and compared. From the predicted values it was possible to verify the potential effect of some production parameters on the variables of interest: (1) - lineage, egg type, incubator brand and egg stocking period; (2) - chicken lineage, sex and weight in the first, second, third and fourth weeks; (3) - sex, chick weight and chicken weight in the second and third weeks; and, (4) - sex, type of chick, lineage, mortality rate in the first, second and third weeks and chicken weight in the second week of rearing. Projections of productive and economic performance were compared with those scenarios considered normal (expected or average) in the context of the available historical data series. Considering production cycles of one million chickens, the estimates economic impact of different scenarios showed that there is a window of opportunity for financial gain or loss that can exceed one million reais per cycle. Besides that, enabling the

prediction values of important production parameters within the poultry integration system, the generated RNA models allowed the realization of productive scenarios simulations.

Keywords: artificial neural networks, industrial poultry, prediction, economic impact

LISTA DE ILUSTRAÇÕES

Figura 1 -	Neurônio artificial proposto por McCulloch e Pitts (1943).....	17
Figura 2 -	Treinamento supervisionado por meio da aprendizagem por correção de erro.....	20
Figura 3 -	Rede neural de múltiplas camadas. Exemplo de rede neural <i>feedforward</i> (FFNN) - o sinal se propaga em sentido único.....	21
Figura 4 -	Rede neural do tipo <i>feed-backward</i> (<i>feed-backward neural network</i> - FBNN).....	22
Figura 5 -	Correlação entre os valores reais e preditos no modelo de rede neural da variável de saída “eclosão vendável” (n=1095 lotes).....	41
Figura 6 -	Correlação entre os valores reais e preditos no modelo de rede neural da variável de saída “peso do frango ao final da quinta semana” (n=399 lotes).....	41
Figura 7 -	Correlação entre os valores reais e preditos no modelo de rede neural da variável de saída “condenação parcial de carcaças” (n=1054 lotes)...	42
Figura 8 -	Correlação entre os valores reais e preditos no modelo de rede neural da variável de saída “condenação total de carcaças” (n=1061 lotes).....	42
Figura 9 -	Valores de eclosão vendável (%) preditos a partir dos cenários produtivos simulados.....	44
Figura 10 -	Peso do frango ao final da quinta semana observado nas simulações dos cenários produtivos 12, 13, 14 e 15.....	45
Figura 11 -	Peso do frango ao final da quinta semana encontrado nas simulações dos cenários produtivos de 16 a 22.....	46
Figura 12 -	Taxa de condenação parcial de carcaças de acordo com o sexo dos frangos de corte alojados. Machos (cenário 23) e fêmeas (cenário 24)...	47
Figura 13 -	Predição da taxa de condenação total de carcaças de acordo com o cenário produtivo simulado (40 a 47).....	49
Figura 14 -	Valores preditos da taxa de condenação total de carcaças de acordo com cada cenário produtivo simulado.....	50
Quadro 1 -	Variáveis de entrada incluídas nos modelos de redes neurais artificiais gerados.....	35
Quadro 2 -	Cenários produtivos simulados para o modelo de rede neural da variável de saída eclosão vendável.....	36

Quadro 3 -	Cenários produtivos simulados para o modelo de rede neural da variável de saída peso do frango ao final da quinta semana de idade.....	36
Quadro 4 -	Cenários produtivos simulados para o modelo de rede neural da variável de saída condenação parcial.....	37
Quadro 5 -	Cenários produtivos simulados para o modelo de rede neural da variável de saída condenação total.....	38
Quadro 6 -	Principais cenários produtivos simulados e a estimativa do seu impacto financeiro na comparação com o cenário normal (médio) encontrado na empresa.....	52

LISTA DE TABELAS

Tabela 1 -	Características dos modelos gerados na fase de treinamento das redes neurais artificiais, para os distintos parâmetros de produção (saídas).....	26
Tabela 2 -	Características matemáticas dos modelos gerados para os distintos indicadores produtivos do incubatório após suas respectivas validações	27
Tabela 3 -	Características matemáticas dos modelos gerados para os distintos parâmetros de produção. Dados após a validação.....	29
Tabela 4 -	Estatística descritiva das principais variáveis numéricas que compõem a base de dados utilizada no estudo.....	33
Tabela 5 -	Parâmetro linhagem expresso de forma binária.....	34
Tabela 6 -	Indicadores de referência para cálculo do potencial de impacto econômico dos cenários produtivos simulados.....	39
Tabela 7 -	Características matemáticas dos modelos gerados para as variáveis eclosão vendável, peso do frango ao final da quinta semana, condenação parcial e condenação total. Dados após o treinamento.....	40
Tabela 8 -	Características matemáticas dos modelos gerados para as variáveis eclosão vendável, peso do frango ao final da quinta semana, condenação parcial e condenação total. Dados após a validação.....	40
Tabela 9 -	Importância relativa de cada variável de entrada no modelo de rede neural gerado para as variáveis de saída eclosão vendável, peso do frango ao final da quinta semana, condenação parcial e condenação total.....	43
Tabela 10 -	Valores preditos pelo modelo de rede neural artificial para a variável condenação parcial de carcaças, de acordo com o respectivo cenário produtivo simulado (25 a 39).....	48

LISTA DE ABREVIATURAS E SIGLAS

ABPA	Associação Brasileira de Proteína Animal
APEC	<i>Escherichia coli</i> Patogênica Aviária
BF	Bolsas de Fabrício
CDPA	Centro de Diagnóstico e Pesquisa em Patologia Aviária
CP	Condenação Parcial
CT	Condenação Total
DP	Desvio Padrão
E	Erro
EM	Erro Médio
EQM	Erro Quadrático Médio
EV	Eclosão Vendável
FBNN	<i>feed-backward neural network</i>
FFNN	<i>feedforward neural network</i>
GRNN	Redes Neurais de Regressão Geral
ID	Número de Identificação
IP	Índice de Patogenicidade
MCP	McCulloch-Pitts
MLP	<i>Multilayer Perceptron</i>
N/A	Não se aplica
PFQS	Peso do Frango de Corte ao Final da Quinta Semana
PIB	Produto Interno Bruto
R	Coefficiente de Correlação
R ²	Coefficiente de Determinação
RNA	Redes Neurais Artificiais
RQME	Raiz do Quadrado Médio do Erro
UFC	Unidades Formadoras de Colônia
UFRGS	Universidade Federal do Rio Grande do Sul

SUMÁRIO

1	INTRODUÇÃO	13
2	REVISÃO BIBLIOGRÁFICA	15
2.1	Setor avícola brasileiro	15
2.2	Redes neurais artificiais	17
2.2.1	Neurônio artificial.....	17
2.2.2	Perceptrons.....	18
2.2.3	Redes neurais de múltiplas camadas.....	20
2.2.4	Algoritmo <i>back-propagation</i>	21
2.2.5	Uso de redes neurais artificiais no gerenciamento do setor avícola - reprodutoras pesadas, incubatório, frango de corte e matadouro-frigorífico.....	24
3	MATERIAL E MÉTODOS	31
3.1	Base de dados	31
3.1.1	Caracterização e análise descritiva das variáveis que compõem o banco de registros.....	31
3.2	Construção, treinamento e validação das redes neurais artificiais	34
3.3	Predição do impacto produtivo e econômico de variáveis do sistema de produção avícola: simulação de cenários	35
4	RESULTADOS E DISCUSSÃO	40
4.1	Características das RNA após elaboração, treinamento e validação	40
4.2	Predição dos cenários produtivos e estimativa do impacto econômico	44
5	CONCLUSÕES	56
	REFERÊNCIAS	57

1 INTRODUÇÃO

O crescimento da produção avícola no Brasil e no mundo tem sido constante. Mesmo com a preferência pela carne suína na Ásia, projeções dão conta de que o consumo mundial de carne de frango será maior que a de suíno nos próximos anos. A aceitação por quase todas as culturas e religiões garante que a avicultura continuará prosperando. O Brasil é o segundo maior produtor mundial de carne de frango, atrás somente dos Estados Unidos, sendo líder nas exportações, com embarques de carne *in natura* superando um montante de 300 mil toneladas mensais.

A afirmação do bom desempenho produtivo e da competitividade da avicultura brasileira passou necessariamente pela busca constante do setor por excelência tecnológica em genética, nutrição, manejo e ambiência, garantindo a maximização da produtividade e minimização dos custos de produção. Embora conhecida como a proteína animal mais eficiente do mundo, ainda há ampla margem para crescimento e desenvolvimento do setor. Por exemplo, atualmente são necessários 1,4kg de ração para produzir 1kg de frango vivo, enquanto a genética já possibilita alcançar uma conversão de 1:1. Ao analisar a cadeia como um todo, acredita-se que a falta de gestão dos processos produtivos seja o principal fator a retardar os ganhos potenciais de eficiência.

Com o crescente desenvolvimento de novas tecnologias da informação, em cenário de franca evolução da ciência e engenharia da computação, o quadro que se impõe no momento para a indústria avícola é o da adoção de ferramentas de gestão que incorporam estas inovações. Profissionais envolvidos nas atividades produtivas, em especial os médicos veterinários, devem buscar e utilizar metodologias que aliem o conhecimento técnico às novas tecnologias, afirmando uma conduta mais resiliente, rompendo com antigos paradigmas e melhorando os processos atuais.

A mesma avicultura que faz uso de equipamentos modernos e serviços atualizados, ainda toma decisões a despeito de aspectos produtivos baseada em critérios subjetivos. Entende-se aqui como critério subjetivo a análise, a interpretação e o entendimento de fenômenos biológicos sustentados apenas pela experiência empírica maior ou menor dos profissionais. Uma atividade que em muito colabora para o desenvolvimento do país, tanto por sua contribuição ao PIB (produto interno bruto) agropecuário, quanto pelo aspecto social, precisa definir critérios objetivos, fundamentados cientificamente, que deem sustentação as suas decisões. Dentro deste contexto, Salle (2018) propõe o uso de modelos matemáticos no

gerenciamento da cadeia avícola, construindo-os a partir de redes neurais artificiais – RNA (um dos ramos da inteligência artificial).

A tecnologia de RNA procura imitar o processo de resolver problemas do nosso cérebro. Assim como o ser humano aplica o conhecimento de experiências passadas para solucionar novos problemas, de igual modo uma RNA analisa casos previamente resolvidos (registro de indicadores de produção, por exemplo) para construir um modelo matemático ajustado de respostas. Projetadas através desse processo de aprendizagem, as RNA buscam resolver problemas por meio do reconhecimento de padrões na inter-relação entre variáveis, solucionando desafios que não podem ser resolvidos pela capacidade computacional dos procedimentos tradicionais e da matemática convencional (ABIODUN *et al.*, 2018).

Atualmente, a aplicação de RNAs se tornou popular em diversas áreas do conhecimento. Muitas organizações estão investindo nas redes neurais para resolver problemas na agricultura, ciência médica, educação, finanças, gerenciamento, segurança, engenharia, comércio de mercadorias, arte, entre outros. Na avicultura, o uso de modelos matemáticos a partir de RNA já foi proposto como ferramenta de gestão para diversos segmentos da cadeia de produção da carne de frango: reprodutoras pesadas (SALLE *et al.*, 2001; 2003; SPOHR, 2011), incubatório (SALLE, 2005; SPOHR, 2011), frango de corte (ROUSH *et al.*, 1997; REALI, 2004; SPOHR, 2011) e matadouro-frigorífico (Dey *et al.*, 2003; PINTO, 2006; SPOHR, 2011). Segundo Salle *et al.* (2001), os modelos de redes neurais têm potencial de aplicação na produção animal na compreensão das relações entre o ambiente e a exploração agropecuária (SALLE *et al.*, 2001; RONDÓN *et al.*, 2002; VIEIRA *et al.*, 2010).

De acordo com Haykin (2001), as redes neurais exploram simultaneamente muitas hipóteses utilizando regras de aprendizagem que permitem adquirir poder de generalização suficiente para reconhecer padrões e prever cenários complexos (de relação não linear). Logo, torna possível a compreensão de fenômenos biológicos de ocorrência comum no contexto da cadeia avícola. É fundamentado nesse conceito que o presente estudo objetivou avaliar a capacidade de modelos de redes neurais artificiais em prever indicadores de produção e o potencial impacto econômico (positivo ou negativo) gerado a partir da inter-relação das variáveis que compõem um sistema de integração avícola. Para isto, cenários produtivos combinando diferentes características das variáveis foram simulados. A elaboração dos modelos se deu a partir de uma base de dados que contempla uma série histórica de registros dos parâmetros de produção dos seguintes segmentos: reprodutoras pesadas, incubatório, frango de corte e matadouro-frigorífico.

2 REVISÃO BIBLIOGRÁFICA

2.1 Setor avícola brasileiro

Dono de campos extensos de grãos, com terras férteis e um clima altamente favorável, o Brasil assumiu para si a responsabilidade como parceiro na segurança alimentar de diversos países pelo mundo. E a avicultura industrial tem seu papel de importância nesse processo.

Nas últimas décadas, com o aumento da demanda por alimentos devido ao crescimento populacional, a produção de frangos de corte tem se destacado pelo fornecimento de proteína animal à população por um preço relativamente menor quando comparado às demais cadeias de produção - principalmente suínos e bovinos.

O Brasil ocupa uma posição de destaque no cenário internacional. Hoje, mais de 150 mercados são importadores da carne de frango *made in Brazil*. Pelos portos do país são quase quatro milhões de toneladas embarcadas anualmente, aproximadamente um terço de tudo o que se produz no país. Ao mesmo tempo, o Brasil alcançou um patamar ímpar quando o assunto é sanidade. Nunca houve qualquer registro de Influenza Aviária em território brasileiro – o único país com este status dentre os grandes produtores avícolas.

Por trás dessa cadeia produtiva estão dezenas de agroindústrias espalhadas por diversos estados brasileiros. Entre produtores, funcionários de empresas e profissionais vinculados direta e indiretamente ao setor, a avicultura reúne mais de 3,5 milhões de trabalhadores. Cerca de 350 mil deles trabalham diretamente nas plantas frigoríficas. No campo, são mais de 130 mil famílias proprietárias de aviários, que trabalham em um sistema totalmente integrado com as agroindústrias (ABPA, 2019). Esta característica merece destaque, pois ao cooptar os pequenos produtores ao processo produtivo, o setor assegura-lhes tecnologia de última geração, capital de giro e garantia de comercialização do produto, tornando viável economicamente o minifúndio e fazendo com que o pequeno produtor rural continue no campo, e não vá se fixar nas periferias das grandes cidades.

O último relatório anual publicado em 2019 pela Associação Brasileira de Proteína Animal (ABPA) traz os resultados do setor avícola alcançados no ano de 2018. O alojamento de matrizes de frango de corte ultrapassou 48 milhões de cabeças e a produção de carne de frango (inteiro, cortes e industrializados) chegou próxima das 13 milhões de toneladas. Em relação ao mercado interno, o brasileiro manteve um consumo per capita de carne de frango próximo ao observado em anos anteriores, 41,99 kg. Em 2018, o Brasil novamente ocupou a posição de maior exportador mundial de carne de frango, 4,101 milhões de toneladas,

superando os Estados Unidos, segundo lugar, em mais de 600 mil toneladas. Dentre os mais de 150 países importadores da carne brasileira, destacam-se, em ordem de volume de compra: China, Arábia Saudita, Japão, África do Sul, Emirados Árabes Unidos e Hong Kong. Do total exportado, 66% foram comercializados na forma de cortes, 27% como frango inteiro e apenas 7% como produto industrializado. As vendas geraram uma receita bruta de aproximadamente 6,5 bilhões de dólares.

Dados referentes às exportações de carne de frango *in natura*, carne salgada e industrializados relativos aos oito primeiros meses de 2019 (dois terços do ano) apontam – comparativamente a idêntico período de 2018 – incremento de 2,73% no volume embarcado e de 10,22% na receita cambial. Embora ligeiramente maior que o registrado um ano atrás, o volume acumulado entre janeiro e agosto de 2019 ainda permanece aquém dos registrados em idêntico período do triênio 2015/2017. Já na receita, o resultado de 2019 está acima não apenas do de 2018, mas também do de 2016. Isso acontece porque o preço médio hoje registrado se encontra mais de 9% acima do alcançado três anos atrás, no mesmo período (AVISITE, 2019).

A crescente demanda por produtos avícolas têm estimulado o setor na busca constante por excelência tecnológica em genética, manejo e ambiência, que garantem a maximização da produtividade e minimizem os custos de produção. Os saltos produtivos alcançados até o momento colocam o Brasil na posição de segundo maior produtor mundial de carne de frango.

Com o grande desenvolvimento de novas tecnologias, o cenário que se impõe no momento para a indústria avícola é o da adoção de ferramentas de gestão por parte dos profissionais envolvidos nas atividades produtivas, em especial os médicos veterinários. A mesma avicultura que usa equipamentos modernos e serviços atualizados ainda toma decisões a despeito de aspectos produtivos apoiada, em muitos casos, em critérios subjetivos.

Dentre as cadeias de produção de proteína animal, certamente a avicultura é a que apresenta o maior número de registro de informações referente ao desempenho produtivo dos seus segmentos. Dada a dimensão alcançada pela maioria das agroindústrias do setor, fica evidente a grandeza das bases de dados. Esses registros contam a história das empresas e podem fornecer informações relevantes no que diz respeito a que práticas de fato estão tendo sucesso e quais as que precisam ser revistas ou substituídas. Para tal, os dados precisam se tornar informações, e, para isso, os médicos veterinários que atuam diretamente no gerenciamento da cadeia de produção precisam ter o domínio das bases e dos fundamentos da modelagem matemática. O conhecimento somente das ciências agrárias já não é mais suficiente, há de se desenvolver novas habilidades e competências. Dentro deste contexto,

acredita-se que a incorporação da ferramenta de redes neurais artificiais possa contribuir nesse processo.

2.2 Redes neurais artificiais


As redes neurais artificiais (RNA) foram desenvolvidas com intuito de simular matematicamente o comportamento de um neurônio biológico. Sua forma de conhecimento é representada em forma de aprendizagem através da experiência (HAYKIN, 2001; BRAGA *et al.*, 2007). Constituindo uma das áreas da inteligência artificial, as RNA são normalmente utilizadas para aproximação de funções universais em paradigmas numéricos devido às suas excelentes propriedades de autoaprendizagem, adaptabilidade, tolerância a falhas e não linearidade (ABIODUN *et al.*, 2018; WANG *et al.*, 2018).

As RNA são um tipo de modelo para aprendizado de máquina (ML, *machine learning*) e tornaram-se relativamente competitivas em relação aos modelos de regressão da estatística convencional no que diz respeito a sua utilidade (DAVE; DUTTA, 2014). Nos últimos tempos, as RNA tornaram-se um modelo popular e útil para classificação, agrupamento, reconhecimento de padrões e previsão em muitas áreas do conhecimento (ABIODUN *et al.*, 2018).

2.2.1 Neurônio artificial

Inicialmente o neurônio artificial (Figura 1) foi proposto em 1943, por McCulloch e Pitts, tentando mimetizar o funcionamento do neurônio biológico, com o que se sabia até o momento. Ficou conhecido como neurônio MCP, referenciando as iniciais de seus criadores.

Figura 1- Neurônio artificial proposto por McCulloch e Pitts (1943).



Fonte: McCulloch e Pitts (1943).

O neurônio artificial ou matemático, também denominado unidade de processamento, recebe sinais de entrada e devolve um único sinal de saída. Sua descrição matemática resulta em um modelo com n terminais de entrada (dendritos) que recebem os valores x_1, x_2, \dots, x_n , que representam o conjunto de variáveis de entrada, e apenas uma variável de saída produzida denominada y (y_i , axônio). Dendritos e axônios são representados matematicamente pelas sinapses (conexões) e a intensidade da ligação é representada por uma grandeza matemática denominada peso sináptico, simbolizada pela letra w (BRAGA *et al.*, 2007; LUDWIG JUNIOR; MONTGOMERY, 2007). Para cada variável de entrada há um peso sináptico associado (w_1, w_2, \dots, w_n).

Um neurônio biológico dispara quando a soma dos impulsos recebidos ultrapassa o seu limiar de excitação. Esse comportamento é representado pelo neurônio artificial de forma que quando as entradas (x) são apresentadas aos neurônios e multiplicadas pelos pesos sinápticos correspondentes (w), e então somados (Σ), esse total representa a saída (y). (BRAGA *et al.*, 2007; LUDWIG JUNIOR; MONTGOMERY, 2007).

Em neurônios naturais os axônios funcionam como filtros de frequência, para que quando houver alguma sinapse, a transferência seja feita com a frequência correta. Em neurônios artificiais são utilizadas funções matemáticas que simulam o funcionamento dos axônios naturais, as funções de ativação ($f(v)$ ou *bias*), que quando os valores de entrada $x = (x_1, x_2, \dots, x_n)$ e seus respectivos pesos $w = (w_1, w_2, \dots, w_n)$ são apresentados a estas funções, resultam em um padrão de saída. Dentre as principais funções de ativação podem se destacar a função degrau, função sigmoideal, ativação linear e gaussiana (BRAGA *et al.*, 2007; LUDWIG JUNIOR; MONTGOMERY, 2007).

2.2.2 Perceptrons

Com o desenvolvimento dos primeiros computadores digitais o pensamento de que se podia desenvolver uma inteligência artificial por meio de operadores lógicos básicos era bastante aceita na época. Em 1958, Frank Rosenblatt propôs o conceito de aprendizagem em redes neurais. O modelo proposto por Rosenblatt, conhecido como perceptrons, era composto de uma estrutura de rede de neurônios MCP (McCulloch-Pitts) e uma regra de aprendizado (BRAGA *et al.*, 2007). Esse modelo era composto por apenas uma camada e tinha como saída um valor binário (HAYKIN, 2001; LUDWIG JUNIOR; MONTGOMERY, 2007).

O aprendizado da rede nesse modelo é feito por meio de ajustes nos pesos sinápticos. Esse ajuste é feito a partir da Regra Delta, criada por Widrow and Hoff em 1960. Essa regra

consiste em ajustar os pesos (w) a partir do erro obtido no valor de saída (resposta) da rede (Equação 1). No início da aprendizagem, a rede neural atribui valores iniciais aleatórios aos pesos de cada uma das variáveis de entrada. Assim, é apresentado um conjunto de valores de entrada (x) e a sua respectiva saída (y), e então é calculada a resposta da rede (valor predito) e comparado com os valores de saída desejados (reais). Caso a diferença entre os valores (erro, Equação 2) seja muito elevada, é realizado o ajuste dos pesos das variáveis de entrada proporcionalmente com o erro encontrado, sendo novamente calculada e comparada a resposta da rede e o erro encontrado. Esse processo é repetido até que se encontre o erro mínimo objetivado. Esse processo é denominado aprendizagem por correção de erro. Como o treinamento da rede ocorre por uma comparação entre a saída desejada (valor real) com a obtida (valor predito), o mesmo é conhecido como treinamento supervisionado. Portanto, o conjunto de exemplos de entrada-saída fornecidos é que orientam a aprendizagem da rede (Figura 2) (HAYKIN, 2001; LUDWIG JUNIOR; MONTGOMERY, 2007).

$$W(i,j)_{T+1} = w(i,j)_T + \eta E(j)_T X_i \quad (1)$$

em que:

- $W(i,j)_{T+1}$: valor do peso corrigido;
- $w(i,j)_T$: valor do peso na iteração anterior;
- η : constante positiva denominada taxa de aprendizado.
- $E(j)_T$: valor do erro para o neurônio artificial j ;
- T : iteração;
- j : índice do neurônio artificial;
- i : índice do sinal de entrada;
- $x(i)$: sinal de entrada.

O erro (E), componente da equação descrita acima, nos modelos de RNAs, é determinado pela diferença entre o valor da variável de saída calculado pela rede (y_c) e o valor desejado, ou real, fornecido à rede (y_d) (Equação 2).

$$E(j) = y_d(i) - y_c(i) \quad (2)$$

Figura 2 - Treinamento supervisionado por meio da aprendizagem por correção de erro.



Fonte: o próprio autor.

2.2.3 Redes neurais de múltiplas camadas

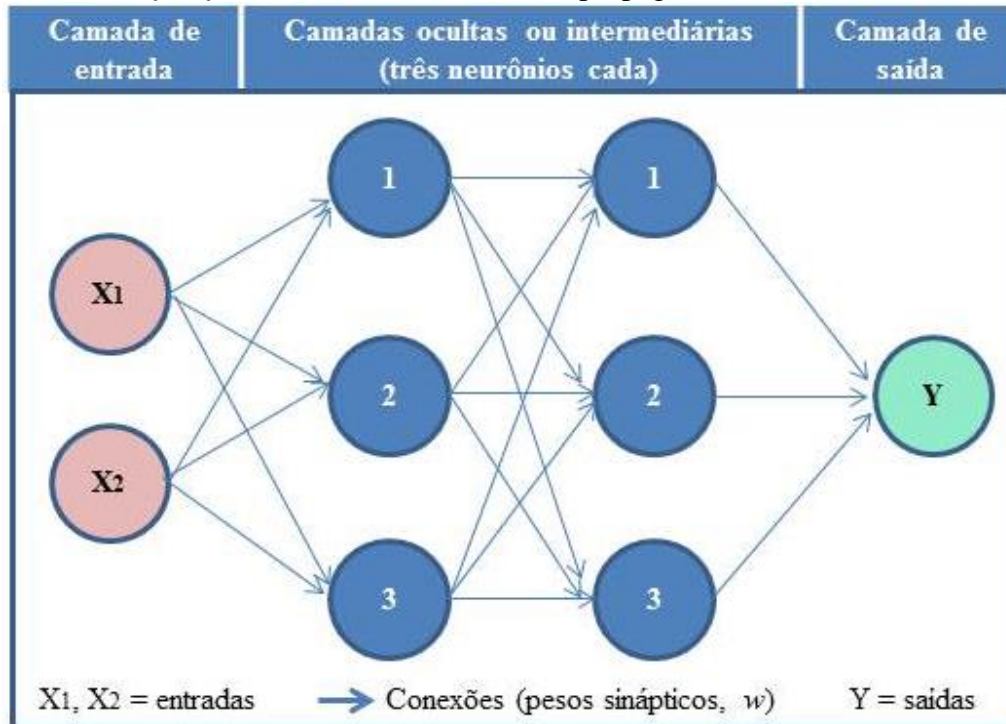
O perceptron simples, ou de camada única, é considerado um algoritmo discriminador, por conseguir apenas solucionar problemas cujas variáveis possuem relação linear. Essa limitação desmotivou os estudiosos da época que sabiam da existência de RNA de múltiplas camadas que poderiam resolver problemas não lineares, mas não sabiam como treiná-las. Esse problema foi solucionado apenas em 1986 com a criação do algoritmo *back-propagation* (MCCLELLAN; RUMELHART, 1987; HAYKIN, 2001; BRAGA *et al.*, 2007;), descrito no item 2.2.4.

RNA de múltiplas camadas, também conhecidas como *Multilayer Perceptron* (MLP), têm poder computacional e matemático muito maior que redes neurais de camada única. RNA de múltiplas camadas (Figura 3) podem resolver problemas tanto de associações lineares quanto de não lineares. O poder de classificação dependerá da arquitetura da rede e do número de neurônios em cada camada oculta (HAYKIN, 2001; BRAGA *et al.*, 2007).

Na Figura 3 os neurônios (unidades de processamento com suas respectivas funções de ativação) em cada camada são representados por círculos, que nas RNA também são chamados de nós. Há duas unidades de entrada (x_1 e x_2 , variáveis de entrada), mas estas não fazem parte de nenhuma camada no sistema de cálculos da rede, pertencem a uma camada virtual. Visualizam-se ainda duas camadas ocultas ou intermediárias, cada uma delas com três neurônios, e uma camada de saída (y , variável de saída). As setas (\rightarrow) representam as conexões sinápticas com os respectivos pesos (w). RNA com duas ou mais camadas ocultas são chamadas de redes profundas, dada a sua maior complexidade em comparação às de uma camada oculta. Cada nó em uma camada se relaciona com todos os nós das outras camadas.

Essas conexões (sinapses) não são todas iguais porque cada conexão pode ter um peso ou valor diferente, conforme descrito no item 2.2.2.

Figura 3- Rede neural de múltiplas camadas. Exemplo de rede neural *feedforward* (FFNN) - o sinal se propaga em sentido único.



Fonte: o próprio autor.

2.2.4 Algoritmo *back-propagation*

O algoritmo *back-propagation*, ou de retropropagação, é uma generalização da Regra Delta em redes de neurônios de múltiplas camadas. Esse algoritmo permite modificar aos poucos os valores das sinapses de modo a aperfeiçoar a saída da rede ao minimizar o erro. O treinamento da rede que utiliza esse algoritmo ocorre em duas fases, sendo que em cada fase a rede de neurônios é percorrida em apenas um sentido. Essas fases são denominadas fase *forward* e fase *backward*. A fase *forward* é utilizada para definir uma saída para um determinado padrão de entradas. Por sua vez, a fase *backward* utiliza a saída desejada (valor real) e a saída calculada (valor predito) pela rede para atualizar os pesos de suas conexões (BRAGA *et al.*, 2007; LUDWIG JUNIOR; MONTGOMERY, 2007).

A fase *forward* consiste nos seguintes procedimentos:

a) o valor da variável de entrada x é apresentado à primeira camada (C_0) da rede; o valor de saída dessa camada proverá como entrada da camada seguinte (C_1), então as saídas

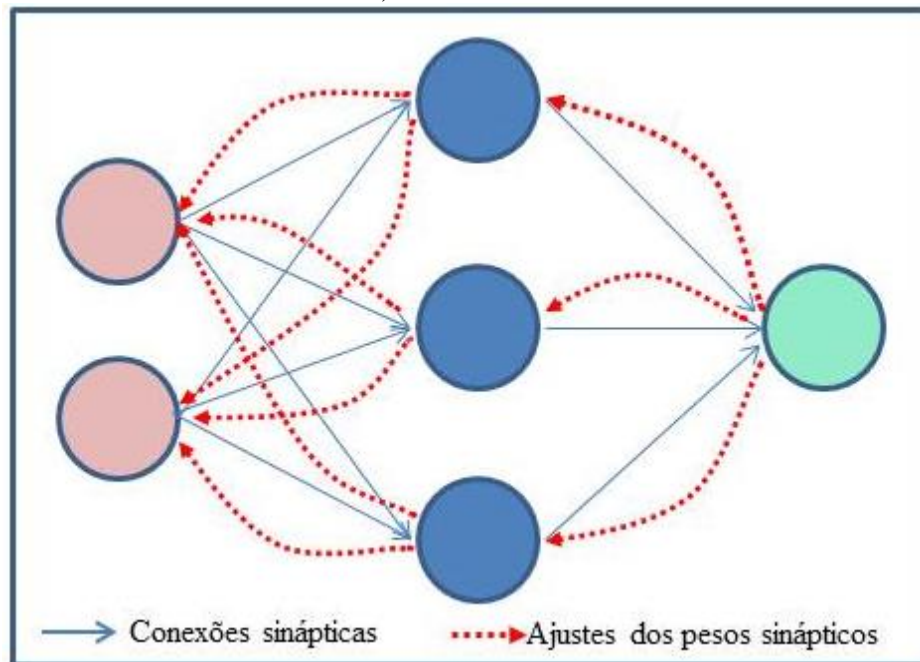
de C_1 serão as entradas de C_2 ; esse processo continua até que se atinja a camada final (C_k), que é a variável de saída da rede; não há retorno de informações entre as camadas;

b) as saídas da ultima camada (preditas pelo modelo) são comparadas com as saídas desejadas (reais), e então é calculado o erro alcançado na rede e inicia-se a fase *backward*.

O objetivo dessa fase é obter o erro total da rede neural, ou seja, o erro da saída após a propagação do sinal em todas as camadas da rede; as informações são transmitidas apenas em um sentido, a partir dos nós de entrada, para os nós ocultos e depois para os nós de saída; devido a esse comportamento elas são chamadas de redes neurais *feedforward* (*feedforward neural network* - FFNN) ou Acíclicas ou Alimentadas Adiante. Exemplos de FFNN são perceptron de camada única e *Multilayer Perceptron* (MLP) (HAYKIN, 2001), como descrito anteriormente. Após obtenção do erro da rede, inicia-se a fase *backward*.

A fase *backward* (Figura 4), por sua vez, ocorre em sentido contrário, da ultima camada até chegar à camada de entrada.

Figura 4 – Rede neural do tipo *feed-backward* (*feed-backward neural network* - FBNN).



Fonte: próprio autor.

A fase *backward* consiste nos seguintes procedimentos:

a) os nós da camada atual (em processamento) ajustam seus pesos de forma a reduzir os erros;

b) o erro de um nó das camadas ocultas ou intermediárias, C_i , é calculado utilizando os erros dos nós das camadas seguintes, C_{i+1} , conectados a eles, ponderados pelos pesos sinápticos entre eles. Assim, o processamento ocorre pelo algoritmo *back-propagation*. Por esse processo de retroalimentação, essas RNA são chamadas de redes neurais *feed-backward* (FBNN) ou Cíclicas ou Recorrentes.

A partir desse entendimento sobre o sistema de aprendizado da rede fica claro o conceito de RNA estabelecido por Haykin (2001): uma RNA é um processador constituído de unidades simples de processamento (neurônios), distribuídas paralelamente, e que têm a capacidade de armazenar conhecimento experimental e torná-lo disponível para o uso. Esse conhecimento é adquirido a partir do ambiente por meio de um processo de aprendizagem e é armazenado por meio de parâmetros ponderados (pesos sinápticos).

Se o problema pode ser aprendido, ou seja, o valor predito pelo modelo se aproxima do valor real, é estabelecido um conjunto estável de pesos para cada variável de entrada, o que garantirá boas respostas para as decisões ou predições das variáveis de interesse (saídas).

O número de neurônios em uma RNA determina a sua capacidade de generalização, tanto quanto sua qualidade na resolução do problema. A determinação do número de neurônios depende da complexidade do problema, sendo uma etapa comumente empírica no desenvolvimento de RNA (HAYKIN, 2001; MEDEIROS, 2006; BRAGA *et al.*, 2007; LUDWIG JUNIOR; MONTGOMERY, 2007).

O poder real das redes neurais fica evidente quando uma rede treinada pode produzir bons resultados para dados que ela desconhece. Ou seja, se após ter sido atingida a melhor configuração, a rede consegue dar boa resposta a novos estímulos (novas entradas) então se diz que a rede generaliza bem e está apta a disponibilizar o conhecimento adquirido para o uso operacional. Esta constatação pode ser verificada na etapa de validação da RNA construída.

Em resumo, RNA procuram por padrões em conjuntos de dados de treinamento, aprende esses padrões e desenvolve a habilidade de corretamente classificar novos padrões ou fazer previsões e classificações. Redes neurais se destacam em problemas de diagnóstico, de tomada de decisão, de classificação e frente a outros desafios onde o reconhecimento de padrões é importante.

São características importantes das RNA (ABIODUN *et al.*, 2018):

- o conhecimento é adquirido por meio de um processo de aprendizagem;
- são modelos adaptativos que apresentam facilidade de treinamento;

- apresentam a capacidade de representar relações/associações complexas (não lineares), importante para análises de fenômenos biológicos;
- possuem a aptidão de generalização mesmo diante de informações incompletas;
- são algoritmos robustos;
- são capazes de fazer armazenamento associativo de informações;
- são capazes de processar informações espaço / temporais;
- dados qualitativos e quantitativos podem facilmente ser incluídos no mesmo modelo.

Dentre as desvantagens do uso da RNA pode-se citar:

- as equações dos modelos que explicam os fenômenos observados não são facilmente compreendidas, dada a complexidade de funções matemáticas que incorpora;
- requer um banco de dados robusto para ser adequadamente treinada e validada.

2.2.5 Uso de redes neurais artificiais no gerenciamento do setor avícola - reprodutoras pesadas, incubatório, frango de corte e matadouro-frigorífico

Redes neurais artificiais foram criadas para assimilar matematicamente o comportamento de um neurônio biológico e assim auxiliar na resolução de problemas complexos e simular a inteligência humana. Com grande poder de aproximação, predição, classificação e regressão, o uso de redes neurais artificiais é amplo para a resolução de problemas (HAYKIN, 2001; MEDEIROS, 2006; BRAGA *et al.*, 2007; LUDWIG JUNIOR; MONTGOMERY, 2007).

Kovács, em 1996, já sugeria que os fenômenos complexos seriam uma área fértil para o desenvolvimento de modelos com redes neurais. A complexidade reside em envolver várias variáveis com causas inter-relacionadas e dependentes, mas que não podem ser explicadas por uma relação linear ou não linear do tipo polinomial de primeira, segunda ou terceira ordem.

Do ponto de vista de modelagens de sistemas biológicos, as RNA têm sido frequente objeto de estudo dos pesquisadores do Centro de Diagnóstico e Pesquisa em Patologia Aviária (CDPA), da Universidade Federal do Rio Grande do Sul (UFRGS), aplicando os modelos nas diversas áreas do setor avícola. Para estes pesquisadores, a abordagem com RNA evoluiu como um ramo da inteligência artificial e é agora uma reconhecida ferramenta para modelar complexidades embutidas em qualquer sistema de produção de aves.

Devido às suas funcionalidades e capacidades poderosas, RNA fornecem uma abordagem alternativa para muitos problemas de manejo, nutrição e sanidade difíceis de serem resolvidos por abordagens convencionais. Previsão de fenômenos biológicos, como,

por exemplo, o ganho de peso de frangos de corte, é um tema de difícil abordagem, principalmente devido à complexidade dos processos envolvidos e à variabilidade do fenômeno no espaço e no tempo.

Salle e colaboradores publicaram em 2001 o primeiro trabalho sobre o tema. Neste utilizaram RNA para estimar parâmetros de produção de galinhas reprodutoras pesadas na fase de recria. Os dados analisados corresponderam há 273 registros semanais de 19 parâmetros de produção. A RNA utilizada apresentava arquitetura de retropropagação, com uma camada de entrada, uma oculta e uma de saída. Duzentos e dezenove registros foram utilizados para treinamento da rede e 54 para sua validação. Foram construídos modelos para os parâmetros mortalidade, peso das aves na semana atual, peso das aves na semana seguinte e quantidade de ração a ser fornecida. A definição de quais variáveis comporiam cada modelo foi realizada de forma empírica. O modelo “quantidade de ração a ser fornecida” foi o que apresentou o menor coeficiente de determinação (R^2), 0,90, que é considerado muito bom, demonstrando que as redes construídas apresentaram um ajuste adequado. Além de demonstrar que era possível explicar os parâmetros de desempenho das aves em recria por meio da modelagem, os autores também conseguiram identificar o percentual de contribuição de cada uma das variáveis sob cada fenômeno em estudo (as quatro variáveis de saída da rede).

Salle *et al.* (2001) acreditam que o conhecimento da contribuição ou da participação de cada uma das entradas sobre a saída escolhida é de fundamental importância para a compreensão do que está interferindo no parâmetro de produção a ser predito. Com este valor à disposição, o profissional pode avaliar e propor as correções pertinentes, quando possíveis e necessárias. Algumas entradas podem ser modificadas, enquanto outras, como idade e estação do ano, são imutáveis. É possível, por exemplo, alterar a temperatura ambiente, a umidade relativa do ar e a quantidade de ração com o intuito de melhorar o peso das aves. Desta forma, RNA tornam-se uma ferramenta de grande importância para o gerenciamento dos processos.

Quando utilizaram RNA para avaliar parâmetros de produção de galinhas reprodutoras pesadas já em fase de produção de ovos, Salle *et al.* (2003) novamente se surpreenderam com a capacidade preditiva dos modelos matemáticos. Com o mesmo modelo de RNA e com uma base de dados mais robusta, pelo maior volume de informações, conseguiram construir 248 modelos para 16 variáveis de saída, muitos deles com elevado R^2 e mínimo erro quadrático médio (EQM).

Reali (2004) verificou o potencial de uso de RNA no gerenciamento da produção de frangos de corte de uma integração avícola do Rio Grande do Sul. A análise compreendeu um

total de 2405 lotes de frangos alojados no período entre 2001 e 2002, com dados de 30 variáveis de desempenho. A Tabela 1 apresenta as características dos 20 modelos matemáticos gerados para os parâmetros produtivos de maior interesse, demonstrando um excelente nível de ajuste matemático em todos eles.

Tabela 1 - Características dos modelos gerados na fase de treinamento das redes neurais artificiais, para os distintos parâmetros de produção (saídas).

Parâmetro de produção	Entradas	Erro médio	QME	R²
Aves abatidas (unidade)	9	29,264580	1.646,648	0,999951
Índice de conversão alimentar	4	0,002841	0,000017	0,997181
Ganho de Peso Diário (g)	5	0,080648	0,012399	0,998634
Índice de Eficiência	9	0,100489	0,100489	0,999951
Peso de frango (kg)	9	317,000800	237382,3	0,998926
Peso líquido de frangos (kg)	3	310,377000	210.111,1	0,999049
Ração consumida (kg)	2	613,795500	1,26E+06	0,998615
Ração de “abate” (kg)	9	266,523200	721.195,3	0,990906
Ração de crescimento (kg)	10	2.383,241000	1,08E+07	0,964697
Ração inicial (kg)	10	548,897300	853.893,7	0,975876
Peso médio (kg)	3	0,009718	0,000227	0,996006
Quantidade de pintos (unidade)	8	36,444840	3.480,517	0,999906
Viabilidade (%)	9	0,093392	0,015514	0,997634
Custo por ave (R\$)	6	0,001067	0,000002	0,999942
Custo do Kg de frango (R\$)	7	0,000517	4,75E-07	0,999905
Custo total do frango (R\$)	5	215,079900	142.066,5	0,999001
Custo do frete das aves (R\$)	7	7,819484	108,0587	0,993630
Custo do frete da ração (R\$)	7	9,448865	177,2076	0,997493
Custo dos pintos (R\$)	5	151,622800	42.968,48	0,991360
Custo total da ração (R\$)	7	215,271200	79.522,31	0,999051

QME = Erro quadrático médio; R² = coeficiente de determinação.

Fonte: Reali (2004).

A validação dos modelos para os parâmetros e indicadores de produção dos lotes de frango de corte confirmou o potencial preditivo das redes elaboradas. Reali (2004) demonstrou ainda a importância relativa das entradas para cada um dos modelos gerados.

O uso de RNA para explicar fenômenos no incubatório foi demonstrado por Salle (2005). Nesse trabalho de pesquisa, o autor propôs analisar uma série histórica de dados de um incubatório de uma empresa avícola do Rio Grande do Sul, compreendendo informações obtidas durante os anos de 1999 a 2003. Foram construídos seis modelos de RNA para as seguintes variáveis: ovos incubáveis, percentagem de ovos incubáveis, ovos incubados, percentagem de ovos incubados, pintos nascidos e pintos aproveitáveis. As características matemáticas que, segundo Salle (2005), comprovam o potencial de predição dos modelos gerados para gerenciamento do incubatório, são apresentadas na Tabela 2. Os dados são referentes aos modelos após sua validação, quando a rede foi testada com o percentual de informações não utilizado na etapa de treinamento.

Tabela 2 - Características matemáticas dos modelos gerados para os distintos indicadores produtivos do incubatório após suas respectivas validações.

Parâmetro	R ²	Erro médio	R	QME	RQME
Ovos incubáveis	0,987707	63788,62	0,993835	6,88E+09	82926,87
Percentagem de ovos incubáveis	0,992903	1,135141	0,996448	2,27658	1,508834
Ovos incubados	0,966384	94149,05	0,983049	1,84E+10	135563,7
Percentagem de ovos incubados	0,930476	3,676742	0,964621	22,75568	4,770291
Pintos nascidos	0,960233	87401,71	0,979915	1,52E+10	123740,7
Pintos aproveitáveis	0,959007	87422,48	0,979289	1,52E+10	123369,0

R² = coeficiente de determinação; R = coeficiente de correlação; QME = quadrado médio do erro; RQME = raiz do quadrado médio do erro.

Fonte: Salle (2005).

De acordo com Salle (2005), a técnica mostrou-se eficiente para realizar simulações, predições e medir a contribuição de cada variável nos fenômenos observados no incubatório.

Em 2003, Dey *et al.* utilizaram RNA na inspeção de frangos de cortes, com o objetivo de diferenciar frangos normais daqueles com septicemia e toxemia. Para isso, foram realizadas medidas espectrais de 300 fígados divididos igualmente em normais e condenados por septicemia e toxemia. A classificação por redes neurais dos dados apresentou uma precisão de 96% na classificação. Roush *et al.* (1997) utilizaram a rede neural como uma predição probabilística de ascite em frangos de corte e concluíram que as RNA podem ser úteis na seleção de linhagens de frangos de corte que não tenham propensão a esse problema.

Contemplando o segmento produtivo responsável pelo processamento industrial, Pinto (2006) se propôs avaliar a possibilidade do uso das RNA no gerenciamento de matadouros-

frigoríficos de aves (empresas A e B). O estudo correspondeu à análise de dados de registros já existentes do sistema de inspeção oficial e de controle de qualidade de dois matadouros do sul do Brasil. Foram treinados e validados três modelos de rede para explicar as variáveis “condenação parcial na inspeção final”, “condenação total na inspeção final” e “condenação total na pré-inspeção”. Os três modelos apresentaram um coeficiente de correlação igual a 1, o que é considerado uma correlação perfeita. Isso foi alcançado, segundo o pesquisador, porque as variáveis de entrada apresentavam uma associação linear entre si. Os resultados encontrados são importantes, porque de certa forma podem facilitar o trabalho dos técnicos da empresa frente a necessidade de direcionar esforços para reduzir as condenações parciais e totais. Pinto (2006) elaborou ainda modelos de rede para as variáveis de saída “peso da carcaça na saída do *chiller*”, “teste de absorção” e “condenação por falha operacional”, e obteve bons resultados de predição.

Spohr (2011) inovou ao propor uma avaliação mais transversal do sistema de produção de carne de frango. Analisou o potencial de uso das RNA a partir de um banco de dados que contemplava informações sobre as atividades de reprodutoras pesadas, incubatório, frango de corte e matadouro-frigorífico de uma mesma agroindústria avícola. O pesquisador conseguiu criar modelos que embutem o efeito de variáveis daqueles segmentos da cadeia que vêm a montante do fenômeno em estudo. Por exemplo, ao avaliar/projetar o “peso do frango de corte na quinta semana” utilizou como variáveis de entrada: idade das matrizes de origem dos ovos, galpão de origem dos ovos, linhagem, tipo de ovo, peso do ovo, tipo de pinto, sexo, peso do pinto, peso do frango na primeira, segunda, terceira e quarta semanas. Esse tipo de modelo de RNA pode permitir um maior grau de generalização dos resultados encontrados, em comparação aos outros estudos, dentro do contexto da empresa detentora daquela realidade retratada pelos registros da base de dados. As características dos modelos gerados por Spohr (2011) são apresentados na Tabela 3.

Em 2006, Rocha defendeu sua tese de doutorado utilizando inteligência artificial para classificação de cepas de *Escherichia coli* quanto ao seu grau de patogenicidade. Na tese são apresentadas três redes neurais artificiais construídas a partir de um banco de dados com as seguintes informações de cada cepa de *E. coli*: presença ou ausência dos genes de virulência *papC*, *felA*, *cvaC*, *iutA*, *iss*, *tsh* e *kpsII*, presença ou ausência de motilidade *in vitro* e índice de patogenicidade (IP, de 0 a 10) *in vivo*, sendo este determinado pela inoculação de pintos de um dia de idade. O objetivo do trabalho foi verificar a capacidades das RNA treinadas e validadas em prever a patogenicidade de cepas de *Escherichia coli* Patogênica Aviária (APEC) sem a necessidade da utilização de animais. A rede um, por contemplar os 11

possíveis IPs, apresentou um índice de acerto de 54,27%, considerado baixo. No intuito de melhorar o desempenho do modelo, Rocha (2006) criou uma segunda rede, utilizando como saídas apenas três grupos de IPs (baixa, média e alta patogenicidade). O índice de acerto na classificação das cepas subiu para 80,55%. Uma terceira rede contemplando apenas dois grupos de IP alcançou uma classificação correta em 83,96% dos casos.

Tabela 3- Características matemáticas dos modelos gerados para os distintos parâmetros de produção. Dados após a validação.

Parâmetro	R ²	Erro médio	R	QME	RQME
Eclosão total (%)	0,894194	0,963802	0,946050	5,928693	2,434891
Eclosão vendável (%)	0,906970	0,913960	0,952996	5,317470	2,305964
Fertilidade (%)	0,913129	0,755201	0,956725	1,420947	1,192035
Mortalidade na primeira semana (%)	0,924788	0,019772	0,964298	0,023466	0,153188
Mortalidade na quinta semana (%)	0,999477	0,004802	0,999742	0,000810	0,028467
Perda de peso do ovo (g)	0,560644	0,178553	0,774043	0,155397	0,394205
Peso do frango na quinta semana (kg)	0,971527	4,434234	0,986405	382,2787	19,55195
Condenação parcial (%)	0,980680	0,012488	0,990372	0,019819	0,140782
Condenação total (%)	0,988910	0,003824	0,994455	0,001201	0,034656

R² = coeficiente de determinação; R = coeficiente de correlação; QME = quadrado médio do erro; RQME = raiz do quadrado médio do erro.

Fonte: Spohr (2011).

Tejkowski (2013) desenvolveu seu trabalho sobre patogenicidade de *E. coli* com uma metodologia muito semelhante à de Rocha (2006). O diferencial foi que utilizou um número maior de cepas (489 isolados) e analisou 38 genes de virulência. Os modelos que construiu para prever a patogenicidade *in vivo* das amostras de APEC apresentaram uma classificação correta acima de 90%, com especificidade de 99,64% e sensibilidade de 92,86%. Assim, os modelos demonstraram ser mais ajustados quando comparados aos obtidos por Rocha (2006).

Salle *et al.* (2010) construíram RNA para prever o comportamento bioquímico de 261 cepas de APEC, tendo como origem cama de aviário, lesões de celulite e quadros respiratórios de frangos de corte. A caracterização completa das cepas envolveu a pesquisa de genes associados à virulência, as lesões provocadas após inoculação de pintos de um dia, o índice de patogenicidade e o perfil de resistência antimicrobiana frente a 14 antibióticos. Todas essas variáveis foram utilizadas como entradas nos diferentes modelos. Sete provas bioquímicas compuseram as saídas. As redes neurais foram capazes de realizar a classificação

do comportamento bioquímico das cepas APEC com um índice de acerto entre 87,80% e 98,37%. A sensibilidade e a especificidade dos modelos classificatórios variaram de 59,32% a 99,47% e de 80,00% a 98,54%, respectivamente.

A avaliação da depleção linfóide em bolsas de Fabrício (BF) sempre foi um desafio para os veterinários patologistas, porque a definição do escore de depleção é realizada de forma subjetiva, pela leitura de lâminas coradas com hematoxilina e eosina. Visando criar um método de avaliação mais preciso e objetivo, Moraes *et al.* (2010) decidiram analisar a depleção linfocitária por meio de imagens digitais de folículos. A partir destas, conseguiram extrair informações em relação aos *pixels* pela avaliação de histogramas, como: índice maior, ponto maior, área esquerda, área direita e área ponto. Os pesquisadores então propuseram treinar redes neurais com estas propriedades de imagem, de uma forma que elas pudessem classificar BF quanto aos seus escores de depleção linfocitária. Considerando a escala usual de cinco escores de depleção, o modelo conseguiu classificar corretamente em aproximadamente 60% dos casos. Segundo Moraes *et al.* (2010), os erros nas predições se encontram nos casos de BF com depleção linfóide intermediária.

Dentre os trabalhos que buscaram avaliar o potencial de aplicação das RNA na avicultura industrial, apenas Salle *et al.*, (2001; 2003) propuseram utilizar os modelos matemáticos gerados para simular, ou prever, o efeito de cada variável de entrada sobre o parâmetro de saída em observação. Os pesquisadores demonstraram, por exemplo, o quanto alterações na quantidade de ração ofertada/fêmea/dia influenciava na produção de ovos do lote na semana seguinte. A predição da produção de ovos das matrizes poderia então ser comparada com o padrão esperado pela empresa e, assim, servir de base para a tomada de decisão quanto a alterar ou não algum manejo, se esta fosse a alternativa. Outro exemplo demonstrado foi a predição do peso das aves a partir do fornecimento de diferentes quantidades de ração. Segundo os pesquisadores, isso permite conhecer quanta ração é necessária para fornecer aos animais para chegar ao peso desejado em determinada idade, aumentando-se a uniformidade dos lotes.

Em resumo, por serem capazes de resolver problemas de aproximação, classificação, categorização, predição, entre outros, a gama de áreas onde as RNA podem ser aplicadas na avicultura é bastante extensa (BRAGA *et al.*, 2000). Cabe aos médicos veterinários e demais profissionais adotarem essa ferramenta de apoio.

3 MATERIAL E MÉTODOS

3.1 Base de dados

O estudo foi realizado a partir de uma série histórica de dados de granjas de matrizes de frango de corte, de um incubatório, de lotes de produção de frangos de corte e de um matadouro-frigorífico de uma empresa avícola do Rio Grande do Sul. Os dados são referentes ao período de produção de julho de 2009 a janeiro de 2010. Os dados fizeram parte da dissertação de mestrado de Augusto Spohr (2011).

3.1.1 Caracterização e análise descritiva das variáveis que compõem o banco de registros

A base de dados analisada no estudo é composta por 2.191 lotes de frangos de corte, totalizando 21 milhões de aves. Cada lote que compõe o banco de dados da empresa possui a informação individual de 40 indicadores (variáveis) de produção, conforme segue:

- aviário de origem dos ovos: total de 91 aviários;
- linhagem: 1- Cobb (n=1821 lotes); 2 - Ross (n=305); 3 - misto (Cobb e Ross, n=64);
- idade média das matrizes (semanas);
- peso do ovo (g);
- tipo de ovo: 1 - ovo limpo de ninho (n=1771); 2 - ovo sujo de ninho (n=335); 3 - ovo de cama (n=84);
- período de estoque dos ovos (horas);
- ovos trincados (%);
- fertilidade (%);
- ovos incubáveis;
- incubadora: 1 - CASP[®] (n=936); 2 - PETERSIME[®] (n=1255);
- tempo de incubação (minutos);
- perda de peso do ovo (g);
- eclosão total (%);
- eclosão vendável (%);
- nascedouro: identificados de 1 a 38;
- número de aviários no nascedouro;
- tempo no nascedouro (minutos);

- *Aspergillus* spp. nos nascedouros: dados expressos em unidades formadoras de colônia (UFC)/10cm² de superfície amostrada;
- *Escherichia coli* nos nascedouros: UFC/10cm²;
- *Pseudomonas* spp. nos nascedouros: UFC/10cm²;
- *Salmonella* spp. nos nascedouros: UFC/10cm²;
- peso de pinto (g);
- aproveitamento de pintos (%);
- contaminação na transferência (%);
- tipo de pinto:
 - 1 – oriundo de matrizes com até 37 semanas de idade (n=1145);
 - 2 – de 38 a 49 semanas (n=766);
 - 3 – acima de 49 semanas (n=279);
- sexo:
 - 1- macho (n=983);
 - 2 – fêmea (n=1117);
 - 3 - misto (macho e fêmea, n=4);
- produtor: total de 138;
- extensionista: total de 23 profissionais;
- peso do frango ao final da primeira semana (g);
- peso do frango ao final da segunda semana (g);
- peso do frango ao final da terceira semana (g);
- peso do frango ao final da quarta semana (g);
- peso do frango ao final da quinta semana (g);
- mortalidade ao final da primeira semana (%);
- mortalidade ao final da segunda semana (%);
- mortalidade ao final da terceira semana (%);
- mortalidade ao final da quarta semana (%);
- mortalidade ao final da quinta semana (%);
- condenação parcial (%).
- condenação total (%);

A Tabela 4 apresenta uma análise descritiva simplificada das principais variáveis numéricas do banco de registros.

Tabela 4 – Estatística descritiva das principais variáveis numéricas que compõem a base de dados utilizada no estudo.

Variável	Mín.	Máx.	Média	Erro médio	Desvio padrão	Total de lotes
Idade da matriz (semanas)	27	72,00	47,06	0,24	11,26	2188
Peso de ovo (g)	67	69,60	67,96	0,01	0,50	2189
Período de estoque dos ovos (h)	0	312,00	113,29	0,83	38,82	2191
Ovos trincados (%)	0	11,43	0,15	0,01	0,68	2190
Fertilidade (%)	74,11	98,96	94,43	0,10	4,03	1540
Ovos incubáveis	19	20160	4224,4	91,39	4276,8	2190
Tempo de incubação (min)	0	30930	30262	18,41	861,53	2191
Perda de peso de ovo (g)	11,2	14,10	12,95	0,01	0,59	2190
Eclosão total (%)	47,12	92,71	81,70	0,16	7,44	2190
Eclosão vendável (%)	46,67	92,45	81,16	0,16	7,53	2190
Nº. de aviários no nascedouro	1	28,00	8,64	0,16	7,71	2190
Tempo no nascedouro (min)	4320	30240	7407,7	179,4	8398,3	2191
* <i>Aspergillus</i> spp.	0	21,00	19,24	18,45	20,12	2191
* <i>E. coli</i> spp.	0	21,00	20,31	18,93	20,60	2191
* <i>Pseudomonas</i> spp.	0	21,00	19,84	18,73	20,40	2191
Peso de pinto (g)	6,32	50,20	45,81	0,07	3,45	2189
Aproveitamento de pintos (%)	94,48	100,00	99,33	0,01	0,47	2191
Peso do frango, 1ª semana (g)	128	246	176,5	0,43	19,41	2026
Peso do frango, 2ª semana (g)	313	558	441,7	1,14	51,01	2008
Peso do frango, 3ª semana (g)	588	1081	856,7	2,36	105,20	1991
Peso do frango, 4ª semana (g)	1052	1772	1374,2	3,83	154,75	1636
Peso do frango, 5ª semana (g)	1650	2390	2123,4	4,07	116,09	815
Mortalidade, 1ª semana (%)	0,22	4,69	0,96	0,01	0,57	2002
Mortalidade, 2ª semana (%)	0,38	5,38	1,50	0,02	0,75	1955
Mortalidade, 3ª semana (%)	0,38	6,41	2,08	0,02	0,93	1848
Mortalidade, 4ª semana (%)	0,95	7,31	2,78	0,03	1,11	1474
Mortalidade, 5ª semana (%)	1,87	7,87	3,55	0,04	1,25	788
Condenação parcial (%)	0,49	6,59	2,79	0,02	1,01	2089
Condenação total (%)	0,08	2,81	0,52	0,01	0,33	2104

*Dados expressos como logaritmo na base 10, unidades formadoras de colônia/10cm² (Log₁₀ UFC/10cm²); EM = erro médio; DP = desvio padrão;

Fonte: o próprio autor.

Os parâmetros referentes à linhagem, tipo de ovo, incubadora, tipo de pinto e sexo (todas variáveis categóricas) foram binarizados, conforme exemplo apresentado na Tabela 6. A inclusão em uma classe foi feita de forma que garantisse a exclusão mútua das demais classes, dentro da mesma variável.

Tabela 5 – Parâmetro linhagem expresso de forma binária.

Cobb	Ross	Misto (Cobb+Ross)
1	0	0
0	1	0
0	0	1

3.2 Construção, treinamento e validação das redes neurais artificiais

O termo “entrada”, neste trabalho refere-se àquelas variáveis, parâmetros ou indicadores produtivos selecionados para compor determinado modelo matemático preditivo, e a palavra “saída” à variável de interesse a ser estimada.

Foram construídas RNA para as variáveis “eclosão vendável”, “peso do frango ao final da quinta semana”, “condenação parcial” e “condenação total” de carcaças. As variáveis de entrada que compuseram cada modelo gerado são apresentadas no Quadro 1. A escolha das variáveis de entrada para cada modelo preditivo foi realizada pelo pesquisador de forma empírica.

Para a elaboração das RNA foi utilizado o *software* NeuroShell[®]Predictor da empresa Ward Systems Group, Inc. O programa usa Redes Neurais de Regressão Geral (GRNN) para resolver problemas de reconhecimento de padrões e de previsão e estimativas de variáveis quaisquer.

Como estratégia de treinamento das RNA foi utilizado o método genético, o qual combina um algoritmo genético com um estimador estatístico. Para esta etapa foram usados os dados individuais de 1.096 lotes (50% dos registros), selecionados de forma aleatória (randomizada).

Os diferentes modelos de RNAs gerados para cada variável predita (saída) foram analisados individualmente, selecionando-se aquele que apresentou os melhores resultados em relação ao coeficiente de determinação múltipla (R^2), coeficiente de correlação (R), erro médio (E), erro quadrático médio (EQM) e raiz do erro quadrático médio (REQM). Esses parâmetros estatísticos foram obtidos na fase de treinamento dos modelos gerados à medida que o modelo matemático gerado confrontava os valores preditos com os valores reais das

respectivas variáveis de saída (eclosão vendável, peso do frango ao final da quinta semana, condenação parcial e condenação total).

Quadro 1 – Variáveis de entrada incluídas nos modelos de redes neurais artificiais gerados.

Eclosão vendável = 1		Condenação parcial = 3	
Peso do frango na quinta semana = 2		Condenação total = 4	
Variável de entrada	RNA	Variável de entrada	RNA
Linhagem	1, 2, 3, 4	Tipo de pinto	2, 3, 4
Idade da matriz (semanas)	1, 2, 3, 4	Peso de pinto (g)	2, 3, 4
Tipo de ovo	1, 2, 3, 4	Sexo	2, 3, 4
Peso de ovo (g)	1	Peso do frango, 1ª semana (g)	2, 3, 4
Período de estoque dos ovos (h)	1	Peso do frango, 2ª semana (g)	2, 3, 4
Ovos trincados (%)	1	Peso do frango, 3ª semana (g)	2, 3, 4
Tipo de incubadora	1	Peso do frango, 4ª semana (g)	2, 3, 4
Tempo de incubação (min)	1	Peso do frango, 5ª semana (g)	3, 4
Nº. de aviários no nascedouro	1	Mortalidade, 1ª semana (%)	3, 4
Tempo no nascedouro (min)	1	Mortalidade, 2ª semana (%)	3, 4
<i>Aspergillus</i> spp.	1, 2, 3, 4	Mortalidade, 3ª semana (%)	3, 4
<i>E. coli</i> spp.	1, 2, 3, 4	Mortalidade, 4ª semana (%)	3, 4
<i>Pseudomonas</i> spp.	1, 2, 3, 4	Mortalidade, 5ª semana (%)	3, 4

RNA = redes neurais artificiais.

Fonte: o próprio autor.

Logo após a etapa de treinamento e de seleção do modelo de rede mais ajustado para cada variável de interesse, realizou-se a etapa de validação do mesmo. Os dados da parcela de lotes não utilizados na etapa de treinamento foram inseridos na RNA, buscando-se verificar sua capacidade preditiva (grau de generalização) frente a registros desconhecidos. O desempenho do modelo gerado foi posteriormente analisado de acordo com o R^2 , R, E, EQM e REQM obtidos.

3.3 Predição do impacto produtivo e econômico de variáveis do sistema de produção avícola: simulação de cenários

Para estimar o impacto positivo ou negativo que algumas variáveis de entrada podem provocar sobre o desempenho das saídas em estudo (eclosão vendável, peso do frango ao final

da quinta semana, condenação parcial e condenação total de carcaças), diferentes cenários produtivos foram simulados, como pode ser observado nos Quadros 2, 3, 4 e 5.

Neste trabalho, a predição das variáveis de saída, a partir do valor médio calculado de cada variável de entrada que compôs os respectivos modelos de rede neural, é entendida como o cenário produtivo padrão, normal ou médio. Pois, entende-se que a média dos indicadores de produção é o parâmetro matemático que melhor representa o conjunto de registros do sistema produtivo avícola da empresa em estudo (série histórica disponível).

Quadro 2 – Cenários produtivos simulados para o modelo de rede neural da variável de saída eclosão vendável.

Cenários produtivos – ECLOSÃO VENDÁVEL (%)		
ID	Variáveis de entrada manipuladas	
1	Cobb x ovo limpo de ninho x CASP®	
2	Cobb x ovo limpo de ninho x Petersime®	
3	Cobb x ovo sujo de ninho x CASP®	
4	Cobb x ovo sujo de ninho x Petersime®	
5	Ross x ovo limpo de ninho x CASP®	
6	Ross x ovo limpo de ninho x Petersime®	
7	Ross x ovo sujo de ninho x CASP®	
8	Ross x ovo sujo de ninho x Petersime®	
	Variáveis de entrada manipuladas (categóricas e numéricas)	Valor simulatório
9	Período de estoque dos ovos (horas) - Médio	113
10	Período de estoque dos ovos (horas) - Reduzido	74
11	Período de estoque dos ovos (horas) - Prolongado	152

ID = número de identificação do cenário produtivo simulado; Médio = cenário produtivo simulado com a média da variável de entrada; Reduzido = média da variável de entrada menos um desvio padrão; Prolongado = média da variável de entrada acrescida de um desvio padrão.

Fonte: o próprio autor.

Quadro 3 – Cenários produtivos simulados para o modelo de rede neural da variável de saída peso do frango ao final da quinta semana de idade.

(continua)

Cenários produtivos – PESO DO FRANGO AO FINAL DA 5ª SEMANA (g)	
ID	Variáveis de entrada manipuladas (categóricas)
12	Cobb, M
13	Cobb, F
14	Ross, M
15	Ross, F

Quadro 3 – Cenários produtivos simulados para o modelo de rede neural da variável de saída peso do frango ao final da quinta semana de idade. (conclusão)

Cenários produtivos – PESO DO FRANGO AO FINAL DA 5ª SEMANA (g)		
ID	Variáveis de entrada manipuladas (categóricas e numéricas)	Valor simulatório
16	Peso do frango na 1ª semana (g), M Médio	184,84
17	Peso do frango na 1ª semana (g), M Superior	203,22
18	Peso do frango na 1ª semana (g), M Inferior	166,46
19	Peso do frango na 2ª semana (g), M Inferior	426,97
20	Peso do frango na 3ª semana (g), M Inferior	834,72
21	Peso do frango na 4ª semana (g), M Inferior	1340,72
22	Peso do frango na 1ª, 2ª e 3ª semanas (g), M Inferior	166,46
		426,97
		834,72

ID = número de identificação do cenário produtivo simulado; M = macho; F = Fêmea; Médio = cenário produtivo simulado com a média da variável de entrada; Superior = média da variável de entrada acrescida de um desvio padrão; Inferior = média da variável de entrada menos um desvio padrão.

Quadro 4 – Cenários produtivos simulados para o modelo de rede neural da variável de saída condenação parcial.

Cenários produtivos – CONDENAÇÃO PARCIAL (%)		
ID	Variáveis de entrada manipuladas (categóricas)	
23	Cobb ou Ross, M	
24	Cobb ou Ross, F	
	Variáveis de entrada manipuladas (categóricas e numéricas)	Valor simulatório
25	Peso de pinto (g), M Médio	45,93
26	Peso de pinto (g), M Superior	49
27	Peso de pinto (g), M Inferior	42,85
28	Peso de pinto (g), F Médio	46,01
29	Peso de pinto (g), F Superior	49,61
30	Peso de pinto (g), F Inferior	42,41
31	Peso de pinto (g), F Máximo	50,2
32	Peso de pinto (g), F Mínimo	33,1
33	Peso do frango na 2ª semana (g), M Médio	467,69
34	Peso do frango na 2ª semana (g), M Superior	508,41
35	Peso do frango na 2ª semana (g), M Inferior	426,97
36	Peso do frango na 3ª semana (g), M Médio	922,5
37	Peso do frango na 3ª semana (g), M Superior	1010,28
38	Peso do frango na 3ª semana (g), M Inferior	834,72
39	Peso do frango na 2ª e 3ª semanas (g), M Inferior	508,41
		1010,28

ID = número de identificação do cenário produtivo simulado; M = macho; F = Fêmea; Médio = cenário produtivo simulado com a média da variável de entrada; Superior = média da variável de entrada acrescida de um desvio padrão; Inferior = média da variável de entrada menos um desvio padrão. Máximo = valor máximo da variável de entrada; Mínima = valor mínimo da variável de entrada.

Quadro 5 – Cenários produtivos simulados para o modelo de rede neural da variável de saída condenação total.

Cenários produtivos – CONDENAÇÃO TOTAL (%)			
ID	Variáveis de entrada manipuladas (categóricas)		
40	Cobb ou Ross, M		
41	Cobb ou Ross, F		
42	Pinto tipo 1, M		
43	Pinto tipo 1, F		
44	Pinto tipo 2, M		
45	Pinto tipo 2, F		
46	Pinto tipo 3, M		
47	Pinto tipo 3, F		
Variáveis de entrada manipuladas (categóricas e numéricas)		Valor simulatório	
48	Baixa mortalidade (%) ¹ , F	1ª semana	0,09
		2ª semana	0,62
		3ª semana	0,97
49	Alta mortalidade (%) ² , F	1ª semana	1,39
		2ª semana	1,7
		3ª semana	2,45
50	Máxima mortalidade (%) ³ , F	1ª semana	2,16
		2ª semana	4,45
		3ª semana	4,06
51	Peso do frango na 2ª semana (g), M	Médio	467,69
52	Peso do frango na 2ª semana (g), M	Superior	508,41
53	Peso do frango na 2ª semana (g), M	Inferior	426,97

ID = número de identificação do cenário produtivo simulado; M = macho; F = Fêmea; ¹Cenário simulado a partir do valor médio de mortalidade menos um desvio padrão; ²Cenário simulado a partir do valor médio de mortalidade acrescido de um desvio padrão; ³Cenário simulado a partir do valor máximo de mortalidade; Médio= cenário produtivo simulado com a média da variável de entrada; Superior = média da variável de entrada acrescida de um desvio padrão; Inferior = média da variável de entrada menos um desvio padrão. Máximo = valor máximo da variável de entrada; Mínima = valor mínimo da variável de entrada.

Fonte: o próprio autor.

Como pode ser observado nos Quadros 2, 3, 4 e 5, para projetar o possível efeito (positivo, negativo ou nulo) de algumas variáveis de entrada sobre determinado cenário produtivo padrão (médio), definiram-se simulações a partir da alteração dos valores das médias dos indicadores (variáveis de entrada), subtraindo-se um desvio padrão da média e somando-se um desvio padrão a média, ou ainda utilizando os valores de máxima e mínima das respectivas variáveis. Ao alterar os valores dos parâmetros buscou-se simular cenários produtivos cujos resultados poderiam representar uma melhora ou piora de desempenho.

Embora algumas variáveis de entrada classificadas como categóricas não apareçam nos cenários produtivos ilustrados nos Quadros 2, 3, 4 e 5, todas compõem seus respectivos modelos - conforme Quadro 1. A inclusão nestes (quando não indicado o grupo da categoria) teve como critério o grupo predominante (maior número de lotes registrados) em cada variável categórica, conforme segue: Cobb, n = 1821 (linhagem); ovo limpo de ninho, n = 1771 (tipo de ovo); Petersime[®], n = 1255 (incubadora); pinto de matrizes com até 37 semanas de idade, n = 1145 (tipo de pinto); e, fêmea, n = 1117 (sexo). A inclusão de apenas um grupo por categoria se fez necessária porque os modelos de RNA não permitem fazer projeções a partir de dois ou mais grupos por variável categórica.

O pacote NeuroShell[®]Run-Time Server foi utilizado na predição dos cenários produtivos simulados neste trabalho, pois permite disparar as redes neurais criadas com o NeuroShell[®]Predictor. Por meio do programa NeuroShell[®]Fire program, o valor predito da variável de saída em estudo era visualizado instantaneamente à medida que se finalizava a inclusão de todos os valores de cada uma das variáveis de entrada que compuseram cada cenário produtivo simulado.

Com base nos resultados obtidos nas predições de cada cenário produtivo simulado, buscou-se estimar o impacto econômico (perdas ou ganhos) para a empresa de tais mudanças de desempenho nos indicadores: eclosão vendável, peso do frango ao final da quinta semana, condenação parcial e condenação total de carcaças. Para todos os cálculos de estimativa econômica definiu-se como unidade de medida, por ciclo de produção, o total de 1.000.000 de aves (pintos de um dia ou frangos de corte). A Tabela 6 apresenta os indicadores de referência utilizados nos cálculos.

Tabela 6 – Indicadores de referência para cálculo do potencial de impacto econômico dos cenários produtivos simulados

Parâmetro	Valor
Rendimento médio por carcaça de frango (kg)	2,50
Preço médio do quilo de frango pago ao produtor (R\$)	3,20
Preço médio do quilo de frango abatido (R\$)	4,10
Condenação parcial média de uma carcaça (%)	20
Preço do pinto de corte (R\$/unidade)	3,00

Fonte: Avisite (2019).

4 RESULTADOS E DISCUSSÃO

4.1 Características das RNA após elaboração, treinamento e validação

As Tabelas 7 e 8 mostram as propriedades de cada modelo de RNA gerado, treinado e validado, de acordo com as variáveis de saída de interesse - eclosão vendável, peso do frango ao final da quinta semana, condenação parcial e condenação total.

Tabela 7 - Características matemáticas dos modelos gerados para as variáveis eclosão vendável, peso do frango ao final da quinta semana, condenação parcial e condenação total. Dados após o treinamento.

Parâmetro	R²	R	Erro médio	EQM	REQM
Eclosão vendável	0,8214	0,9066	1,9299	9,9593	3,1558
Peso do frango na quinta semana	0,9998	0,9999	0,1577	2,8144	1,6776
Condenação parcial	0,9837	0,9918	0,0183	0,0171	0,1306
Condenação total	0,9961	0,9880	0,0027	0,0004	0,0201

R² = coeficiente de determinação múltiplo; R = coeficiente de correlação; QME = erro quadrático médio; REQM = raiz do erro quadrático médio.

Fonte: o próprio autor.

Dentre os modelos gerados, o que apresentou um menor nível de ajuste foi o elaborado para a variável eclosão vendável, com valores de R² e R aquém dos demais modelos, e por consequência, maiores EM, EQM e REQM.

Tabela 8 - Características matemáticas dos modelos gerados para as variáveis eclosão vendável, peso do frango ao final da quinta semana, condenação parcial e condenação total. Dados após a validação.

Parâmetro	R²	Erro médio	EQM	REQM
Eclosão vendável	0,8236	1,8801	10,1390	3,1842
Peso do frango na quinta semana	0,9623	3,5230	502,1338	22,4083
Condenação parcial	0,9677	0,0261	0,0323	0,1798
Condenação total	0,9761	0,0049	0,0027	0,0524

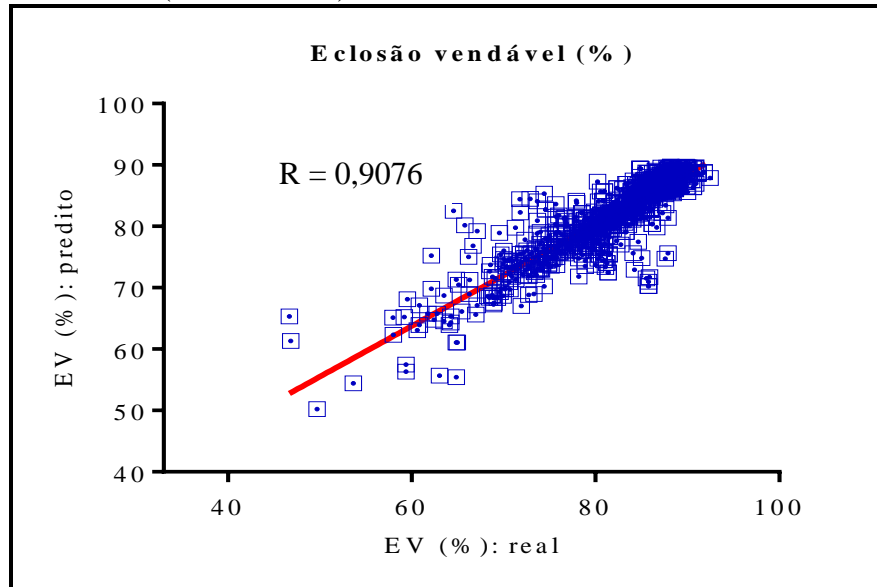
R² = coeficiente de determinação múltiplo; QME = erro quadrático médio; REQM = raiz do erro quadrático médio.

Fonte: o próprio autor.

As Figuras 5, 6, 7 e 8 ilustram a correlação encontrada entre os valores preditos pelos modelos de RNA gerados e os valores reais de cada uma das quatro variáveis de saída em estudo. Os valores de coeficiente de correlação observados indicaram que houve uma alta


correlação (associação) entre os dados reais e os preditos, atestando que os quadro modelos de redes neurais criados estavam adequadamente ajustados e, portanto, poderiam ser utilizados para as simulações dos cenários produtivos.

Figura 5 - Correlação entre os valores reais e preditos no modelo de rede neural da variável de saída “eclosão vendável” (n=1095 lotes).



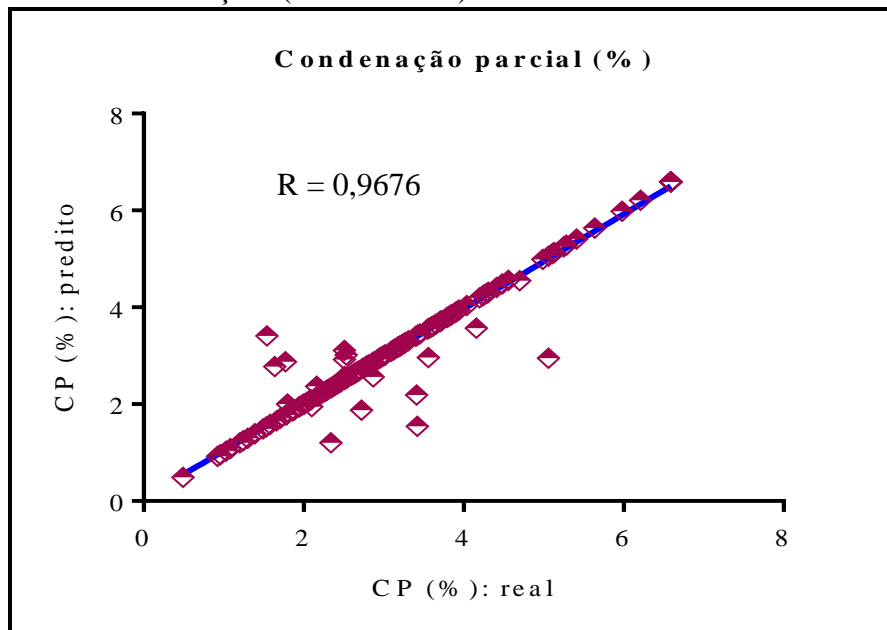
EV = eclosão vendável; R = coeficiente de correlação de Pearson.
Fonte: o próprio autor.

Figura 6 - Correlação entre os valores reais e preditos no modelo de rede neural da variável de saída “peso do frango ao final da quinta semana” (n=399 lotes).



R = coeficiente de correlação de Pearson.
Fonte: o próprio autor.

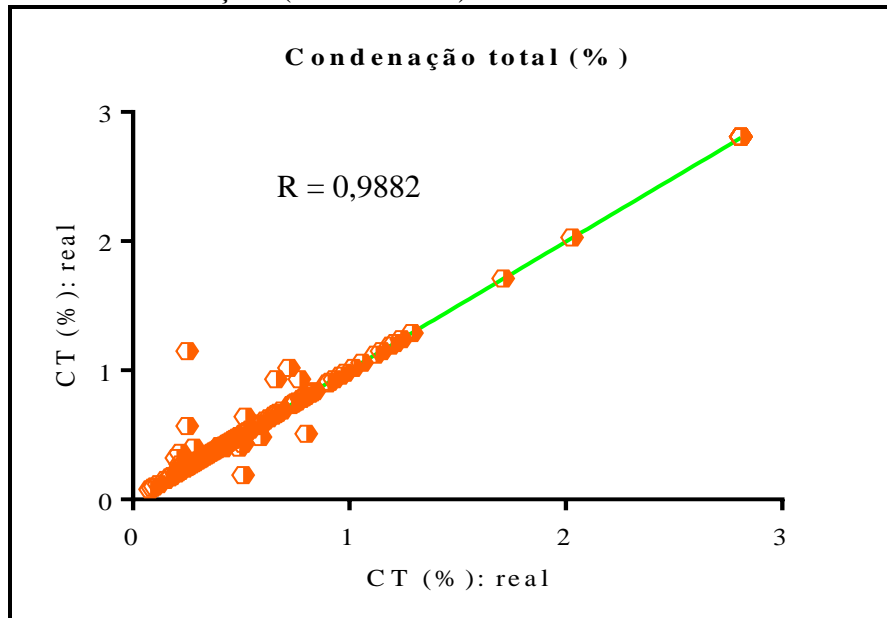
Figura 7 - Correlação entre os valores reais e preditos no modelo de rede neural da variável de saída “condenação parcial de carcaças” (n=1054 lotes).



CP = condenação parcial; R = coeficiente de correlação de Pearson.

Fonte: o próprio autor.

Figura 8 - Correlação entre os valores reais e preditos no modelo de rede neural da variável de saída “condenação total de carcaças” (n=1061 lotes).



CT = condenação total; R = coeficiente de correlação de Pearson.

Fonte: o próprio autor.

A Tabela 9 apresenta a importância relativa de cada variável de entrada no modelo de rede neural gerado para cada variável de saída.

Tabela 9 - Importância relativa de cada variável de entrada no modelo de rede neural gerado para as variáveis de saída eclosão vendável, peso do frango ao final da quinta semana, condenação parcial e condenação total.

Variável		EV	PFQS	CP	CT
Linhagem	Cobb	0,096	0,024	0,012	0,012
	Ross	0,041	0,058	0,018	0,013
	Misto ¹	0,020	0,009	0,001	0,002
Idade da matriz		0,147	0,021	0,018	0,023
Tipo de ovo	Ovo limpo de ninho	0,107	0,090	0,006	0,016
	Ovo sujo de ninho	0,118	0,013	0,009	0,028
	Ovo de cama	0,069	0,050	0,007	0,036
Peso de ovo		0,017	-	-	-
Período de estoque dos ovos		0,031	-	-	-
Ovos trincados		0,001	-	-	-
Tipo de incubadora	CASP®	0,135	-	-	-
	PETERSIME®	0,136	-	-	-
Tempo de incubação		0,063	-	-	-
Aviários no nascedouro		0,010	-	-	-
Tempo no nascedouro		0,001	-	-	-
<i>Aspergillus</i> spp.		0,001	0,006	0,001	0,003
<i>E. coli</i> spp.		0,007	0,002	0,024	0,011
<i>Pseudomonas</i> spp.		0,002	0,013	0,005	0,022
Tipo de pinto ²	27-37	-	0,009	0,000	0,000
	38-49	-	0,009	0,001	0,001
	> 49	-	0,044	0,004	0,004
Peso de pinto		-	0,031	0,006	0,000
Sexo	Macho	-	0,075	0,088	0,006
	Fêmea	-	0,093	0,070	0,010
	Misto ³	-	-	0,081	0,016
Peso do frango, 1ª semana		-	0,122	0,063	0,030
Peso do frango, 2ª semana		-	0,106	0,064	0,103
Peso do frango, 3ª semana		-	0,124	0,079	0,101
Peso do frango, 4ª semana		-	0,101	0,057	0,097
Peso do frango, 5ª semana		-	-	0,088	0,095
Mortalidade, 1ª semana		-	-	0,047	0,097
Mortalidade, 2ª semana		-	-	0,084	0,059
Mortalidade, 3ª semana		-	-	0,071	0,104
Mortalidade, 4ª semana		-	-	0,001	0,058
Mortalidade, 5ª semana		-	-	0,091	0,055


EV = eclosão vendável; PFQS = peso do frango de corte ao final da quinta semana; CP = condenação parcial; CT = condenação total; ¹Cobb + Ross; ²tipo de pinto de acordo com a idade das matrizes (semanas); ³Macho + fêmea; - = não se aplica

Fonte: o próprio autor.

4.2 Predição dos cenários produtivos e estimativa do impacto econômico

A Figura 9 ilustra os resultados de eclosão vendável obtidos a partir da simulação dos cenários produtivos correspondentes.

Figura 9 – Valores de eclosão vendável (%) preditos a partir dos cenários produtivos simulados.



- | | |
|---|--|
| 1. Cobb x ovo limpo de ninho x CASP® | 7. Ross x ovo sujo de ninho x CASP® |
| 2. Cobb x ovo limpo de ninho x Petersime® | 8. Ross x ovo sujo de ninho x Petersime® |
| 3. Cobb x ovo sujo de ninho x CASP® | 9. Período de estoque dos ovos - médio |
| 4. Cobb x ovo sujo de ninho x Petersime® | 10. Período de estoque dos ovos - reduzido |
| 5. Ross x ovo limpo de ninho x CASP® | 11. Período de estoque dos ovos - prolongado |
| 6. Ross x ovo limpo de ninho x Petersime® | |

Médio = cenário produtivo simulado com a média da variável de entrada;

Reduzido = média da variável de entrada menos um desvio padrão.

Prolongado = média da variável de entrada acrescida de um desvio padrão;

Fonte: o próprio autor.

O pinto de corte tem sido comercializado pelo valor médio de R\$3,00/unidade. Considerando um total de 1.000.000 de ovos incubados, cada 0,1% de acréscimo na taxa de eclosão vendável significa 1000 pintos a mais para comercialização. Multiplicando-se este total pelo valor unitário do pinto de corte, a empresa tem um aumento na sua receita bruta de pelo menos R\$3.000,00 para cada 0,1% de aumento na eclosão.


Ao avaliarmos as taxas de eclosão vendável preditas de acordo com as simulações dos cenários produtivos de 1 a 8 é possível identificar que a incubadora CASP® teve um melhor desempenho no comparativo com a Petersime®. A diferença nas taxas de eclosão vendável foi de 4,9% no comparativo dos cenários 1 e 2, os quais contemplam a principal linhagem utilizada na empresa (Cobb, 1821 lotes, 83,11% do total de lotes) e o tipo de ovo

predominante no sistema de produção avícola (ovo limpo de ninho, 1771 lotes, 80,83%). Sendo assim, a diferença monetária entre utilizar uma ou outra incubadora é de aproximadamente R\$147.000,00, considerando a incubação de um milhão de ovos nas mesmas condições simuladas nos cenários 1 e 2. A diferença de eclosão observada na incubação de ovos da linhagem Ross (cenários 5 e 6) foi de 1,91%, o que pode representar um acréscimo de R\$57.300,00 quando da utilização da incubadora CASP[®]. Um desempenho ainda superior é verificado na comparação dos cenários 7 e 8, com diferença de 20,45% entre as taxas de eclosão.

Pelas projeções também foi possível identificar que ao reduzir de 113h (cenário 9) para 74h (cenário 10), o período de estoque dos ovos embrionados, ocorre um ganho de 0,9% na taxa de eclosão vendável (R\$27.000,00). Este resultado projetado, por exemplo, pode servir como argumento ao gerente do incubatório para uma futura mudança de procedimentos, visando reduzir o tempo de espera dos ovos embrionados na sala de ovos.

As Figuras 10 e 11 mostram as projeções de peso do frango de corte ao final da quinta semana a partir dos diferentes cenários produtivos simulados.

Figura 10 - Peso do frango ao final da quinta semana observado nas simulações dos cenários produtivos 12, 13, 14 e 15.




PFQS = Peso do frango ao final da quinta semana. M = macho; F = fêmea;
Fonte: o próprio autor.

As predições do peso que o frango de corte atinge ao final da quinta semana de idade, dentro dos cenários simulatórios construídos para esta variável, revelam resultados interessantes quanto ao desempenho das diferentes genéticas (linhagens) no contexto da empresa. Machos da linhagem Cobb alcançam um peso ao final da quinta semana de criação aproximadamente 4,88% (98g) superior em comparação aos machos da linhagem Ross. Considerando-se o preço de R\$3,20/kg de peso vivo do frango que as empresas estão pagando

para seus produtores integrados, uma diferença de 98 gramas no ganho de peso pode representar um aumento de R\$0,31 por frango abatido. Calculando-se a receita bruta a partir de um ciclo de produção com um milhão de aves abatidas, e que todas são machos, o montante monetário acrescido supera o valor de R\$310.000,00. Sabendo-se que existem indústrias avícolas no Brasil, como a Cooperativa Aurora, que abatem um milhão de aves/dia, fica ainda mais evidente a dimensão do impacto econômico que se projeta. No comparativo dos lotes de fêmeas entre as linhagens não foi observado diferença de desempenho – cenários 13 e 15.

O melhor desempenho do frango em relação ao peso na quinta semana da linhagem Cobb justifica a política adotada pela empresa pelo uso predominante (83,11%) desta genética. Entretanto, é importante salientar que essas projeções de desempenho apenas são possíveis graças à elaboração do modelo de rede neural artificial.

Figura 11 – Peso do frango ao final da quinta semana encontrado nas simulações dos cenários produtivos de 16 a 22.



- 16. Macho, peso do frango, 1ª semana - Médio
- 17. Macho, peso do frango, 1ª semana - Superior
- 18. Macho, peso do frango, 1ª semana - Inferior
- 19. Macho, peso do frango, 2ª semana - Inferior
- 20. Macho, peso do frango, 3ª semana - Inferior
- 21. Macho, peso do frango, 4ª semana - Inferior
- 22. Macho, peso do frango, 1ª, 2ª e 3ª semanas - Inferior

PFQS = Peso do frango ao final da quinta semana.

Médio = cenário produtivo simulado com a média da variável de entrada;

Superior = média da variável de entrada acrescida de um desvio padrão;

Inferior = média da variável de entrada menos um desvio padrão.

Fonte: o próprio autor.

Na análise dos cenários 17 e 18, que simulam o aumento e a redução, respectivamente, do peso do frango ao final da primeira semana, e o possível impacto sobre o peso na quinta


semana, verifica-se um efeito positivo (aumento de 50g e 18g no peso final). Esses resultados preditos revelam que variações de peso na primeira semana entre 166,46g e 203,22g não têm grande influência sobre o peso do frango ao final da quinta semana. Uma hipótese possível seria um ganho compensatório de peso nas semanas subsequentes.

Ao contrário do encontrado no cenário 18, as simulações com os cenários 19, 20 e 21 demonstram que o frango que chega ao final da segunda, ou terceira, ou quarta semanas com peso abaixo do seu potencial médio terá um menor peso também na quinta semana. O cenário 20, por exemplo, projeta que o frango com baixo peso na terceira semana (834,72g, frente ao peso médio de 922,5g) chegará ao final da quinta semana com peso de aproximadamente 2046g, 154g abaixo da média (padrão aguardado pela empresa). Calculando-se novamente o potencial de perda de receita bruta, tendo como referência o preço de R\$3,20/kg de peso vivo do frango, chega-se a um montante equivalente a R\$490.000,00 (redução de R\$0,49/frango vivo). Cabe destacar que falhas simples de manejo das aves e do ambiente já são capazes de causar as quedas de desempenho projetadas nos cenários 19, 20, 21 e 22.

Conhecendo-se previamente o potencial impacto negativo que a perda de peso do frango nas primeiras semanas pode acarretar sobre o peso final da carcaça, medidas podem ser adotadas pela empresa com a finalidade de evitar a ocorrência de tais cenários.

A Figura 12 e a Tabela 10 mostram as estimativas das taxas de condenação parcial de carcaças a partir dos cenários produtivos simulados.

Figura 12–Taxa de condenação parcial de carcaças de acordo com o sexo dos frangos de corte alojados. Machos (cenário 23) e fêmeas (cenário 24).



M = macho; F = fêmea.

Fonte: o próprio autor.

Conforme simulação dos cenários 23 e 24, os valores preditos demonstram que lotes de fêmeas, sejam da linhagem Cobb ou Ross, apresentam uma maior taxa de condenação

parcial de carcaças quando comparados aos lotes de machos. A diferença é de 0,25%, um valor bastante considerável se tratando de condenação de carcaças. Como parâmetro base para cálculos econômicos de perdas e de ganhos de receita, definiu-se como condenação parcial o descarte de 20% do peso total de uma carcaça com rendimento de 2,5kg, o que equivale a uma perda final de 500g/carcaça de frango abatido. Logo, 0,25% de condenações parciais em lotes de fêmeas que somados totalizam hipoteticamente um milhão de aves abatidas, tem-se 2500 carcaças condenadas parcialmente. Ao considerar o preço do frango abatido sendo R\$4,10/kg, os 1250kg de carcaça descartados (500g/carcaça) somam uma perda econômica de cerca de R\$5.125,00. Pode parecer pouco, mas para uma empresa que abate um milhão de aves/dia, em um mês de abate (15 dias em funcionamento), sendo 50% dos lotes fêmeas, acumula-se uma perda de no mínimo R\$76.875,00.

Tabela 10 – Valores preditos pelo modelo de rede neural artificial para a variável condenação parcial de carcaças, de acordo com o cenário produtivo simulado (25 a 39).

Cenários produtivos - condenação parcial de carcaças				
ID	Variáveis de entrada manipuladas		Valor predito (%)	Diferença*
25	Peso de pinto (g), M	Médio	3,81	N/A
26	Peso de pinto (g), M	Superior	3,81	0
27	Peso de pinto (g), M	Inferior	3,81	0
28	Peso de pinto (g), F	Médio	4,06	N/A
29	Peso de pinto (g), F	Superior	4,01	-0,05
30	Peso de pinto (g), F	Inferior	4,10	0,04
31	Peso de pinto (g), F	Máximo	4,00	-0,06
32	Peso de pinto (g), F	Mínimo	4,22	0,16
33	Peso do frango na 2ª semana (g), M	Médio	3,66	N/A
34	Peso do frango na 2ª semana (g), M	Superior	2,96	-0,70
35	Peso do frango na 2ª semana (g), M	Inferior	3,81	0,15
36	Peso do frango na 3ª semana (g), M	Médio	3,66	N/A
37	Peso do frango na 3ª semana (g), M	Superior	2,95	-0,71
38	Peso do frango na 3ª semana (g), M	Inferior	3,81	0,15
39	Peso do frango na 2ª e 3ª semanas (g), M	Superior	2,55	-1,11

ID = número de identificação do cenário produtivo simulado; M = macho; F = fêmea; N/A = não se aplica. * Diferença = valor predito – valor médio correspondente; Médio = cenário produtivo simulado com a média da variável de entrada; Superior = média da variável de entrada acrescida de um desvio padrão; Inferior = média da variável de entrada menos um desvio padrão; Máximo = valor máximo encontrado na série histórica de registros. Mínimo = valor mínimo encontrado na série histórica de registros.

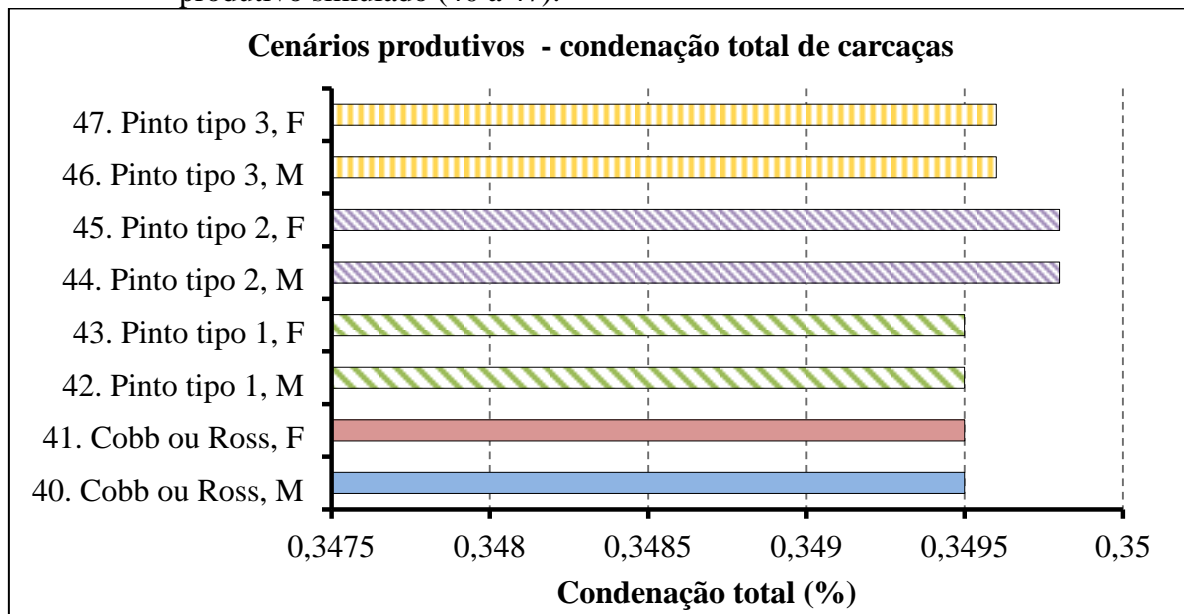
Fonte: o próprio autor.

Com os cenários de 25 a 31 se propôs avaliar o efeito do peso do pinto de um dia de idade sobre a taxa de condenação parcial. Valores preditos demonstram que o impacto é praticamente nulo. Lotes de frangos de corte de pintos alojados mais leves ou mais pesados têm a mesma taxa de condenação parcial de carcaças, levando-se em consideração os resultados das simulações realizadas. A exceção fica por conta do cenário 32, no qual pintos com peso mínimo (33,1g, frente ao peso médio de 46,01g) têm taxa de condenação de carcaças levemente superior ao esperado, 4,22% e 4,06%, respectivamente.

O efeito do peso do frango ao final da segunda e terceira semanas sobre a taxa de condenação parcial de carcaças foi analisado por meio dos cenários simulatórios de 33 a 39. Tanto nas projeções simplificadas (cenários de 33 a 38) quanto na combinada, pôde-se verificar que à medida que o peso do frango foi maior nas referidas semanas de criação, a taxa de condenação parcial de carcaças foi menor. As predições nos cenários 34, 37 e 39 dão conta de que ocorrem reduções próximas a 0,7%, 0,71% e 1,11%, respectivamente. Usando o cenário 39 como base, pode-se afirmar que adotar estratégias de criação e de manejo que possibilitem um maior ganho de peso dos animais nessa fase de desenvolvimento, podem garantir um aporte de até R\$22.755,00 na receita bruta da empresa a cada ciclo de um milhão de aves abatidas, considerando a redução projetada na taxa de condenação parcial.

As Figuras 13 e 14 ilustram os valores preditos para a variável de saída “condenação total de carcaças” de acordo com os cenários produtivos simulatórios.

Figura 13 – Predição da taxa de condenação total de carcaças de acordo com o cenário produtivo simulado (40 a 47).




M = macho; F = fêmea; Pintos tipo 1, 2 e 3 = oriundos de matrizes com idade entre 27 e 37, 38 e 49 ou >49 semanas, respectivamente.

Fonte: o próprio autor.

Nos cenários 23 e 24 verificou-se que lotes de frango do sexo fêmea apresentam uma maior taxa de condenação parcial quando comparados com os de macho, no entanto isso não se repete na taxa de condenação total (cenários 40 e 41, Figura 13). O mesmo efeito nulo também foi observado nas projeções em que se propôs avaliar a contribuição do tipo de pinto sobre a taxa de condenação parcial. De uma forma geral, o modelo de predições demonstra que utilizar pintos do tipo 1, 2 ou 3, de ambos os sexos, tendem a ter o mesmo desempenho no que se refere ao parâmetro condenação de carcaças, no contexto do sistema de produção da empresa.

Figura 14 – Valores preditos da taxa de condenação total de carcaças de acordo com cada cenário produtivo simulado.



41. Fêmea, média mortalidade na 1ª, 2ª e 3ª semanas (%)
48. Fêmea, baixa mortalidade na 1ª, 2ª e 3ª semanas (%)
49. Fêmea, alta mortalidade na 1ª, 2ª e 3ª semanas (%)
50. Fêmea, máxima mortalidade na 1ª, 2ª e 3ª semanas (%)
51. Macho, peso do frango na 2ª semana (g) - Médio
52. Macho, peso do frango na 2ª semana (g) - Superior
53. Macho, peso do frango na 2ª semana (g) - Inferior

Fonte: o próprio autor.

A Figura 14, a partir dos cenários simulatórios 48, 49 e 50, ilustra o impacto potencial que a ocorrência de mortalidade acumulada (baixa ou alta) em mais de uma semana de criação dos frangos pode acarretar sobre a condenação total de carcaças no matadouro-frigorífico da empresa, com base na sua série histórica de registros. Ao se reduzir as taxas de mortalidade nas semanas 1, 2 e 3 (média de 0,74%, 1,16% e 1,71%, respectivamente) em pelo menos um desvio padrão (cenário 48), verificou-se uma diminuição no valor predito da taxa de condenação total de carcaças. A diferença entre a taxa média esperada (cenário 41) e a

projetada pelo cenário 48 é de aproximadamente -0,0795%. Este percentual calculado sobre um ciclo de produção com um milhão de aves traz como estimativa uma redução na condenação de pelo menos 795 carcaças. Considerando o rendimento por carcaça de 2,5kg e o preço médio de R\$4,20/kg do frango abatido, projeta-se um ganho na receita bruta de cerca de R\$8.347,00.

O cenário produtivo 50 simulou o pior quadro possível, à medida que projeta a ocorrência de mortalidade máxima combinada nas três primeiras semanas de criação (2,16%, 4,45% e 4,06%, respectivamente). O reflexo observado (predito) foi um aumento de 0,9405% na taxa de condenação total, que economicamente se traduz, conforme base de cálculos apresentada, em uma perda de receita de aproximadamente R\$98.752,50 a cada um milhão de aves abatidas. Diversas enfermidades de ocorrência comum na avicultura, ou mesmo problemas eventuais de manejo, podem provocar esse quadro de mortalidade (cenário 50).

A mortalidade elevada é um indicativo de doença nos lotes de produção. Aquelas aves que eventualmente não morrem pela infecção têm seu desempenho produtivo comprometido, o que leva a uma maior desuniformidade no peso de carcaças. Estas prejudicam a etapa de eventração automática no abatedouro por ocasionar o rompimento de vísceras e extravasamento de conteúdo intestinal. Logo, lotes com maiores taxas de mortalidade tendem a maximizar as condenações parciais e totais de carcaças no matadouro-frigorífico.

As simulações que buscam avaliar o efeito do peso do frango na segunda semana sobre a taxa de condenação total (cenários 52 e 53) demonstram que tanto uma redução quanto um aumento do peso do frango nessa idade podem resultar em uma diminuição na taxa de condenação. Esses são exemplos de cenários simulados em que os resultados preditos são de difícil compreensão, pois carecem de uma explicação mais lógica (relação linear). Por outro lado, frente a esta situação, não se pode duvidar dos modelos preditivos, pois estes apresentam grande capacidade assertiva, conforme verificado na etapa de validação.

No Quadro 6 é apresentado um resumo dos principais cenários simulados e o seu impacto do ponto de vista financeiro.

Quadro 6 – Principais cenários produtivos simulados e a estimativa do seu impacto financeiro na comparação com o cenário normal (médio) encontrado na empresa.

(continua)

Cenário produtivo simulado		¹ Dife- rença	Impacto financeiro (R\$)
ID	Variáveis alteradas		
ECLOSÃO VENDÁVEL (%)			
1*	Cobb x ovo limpo de ninho x CASP®	4,9	147.000,00
2	Cobb x ovo limpo de ninho x Petersime®		
5*	Ross x ovo limpo de ninho x CASP®	1,91	57.300,00
6	Ross x ovo limpo de ninho x Petersime®		
7*	Ross x ovo sujo de ninho x CASP®	20,45	613.500,00
8	Ross x ovo sujo de ninho x Petersime®		
9	Período de estoque dos ovos – médio (113h)	0,9	27.000,00
10*	Período de estoque dos ovos – reduzido (74h)		
PESO DO FRANGO AO FINAL DA QUINTA SEMANA (g)			
12*	Coob, M (2010g)	98	310.000,00
14	Ross, M (1912g)		
16	Peso do frango na 1ª semana, Médio (184,84g), M	50	159.090,00
17*	Peso do frango na 1ª semana, Superior (203,22g), M		
	Peso do frango na 3ª semana, Médio (922,5g), M	-154	-490.000,00
20*	Peso do frango na 3ª semana, Inferior (834,7g), M		
	Peso do frango na 4ª semana, Médio (1462,01), M	-195	-620.454,00
21*	Peso do frango na 4ª semana, Inferior (1340g), M		
CONDENAÇÃO PARCIAL DE CARCAÇAS (%)			
23	Cobb ou Ross, M (3,81%)	0,25	-5.125,00
24*	Cobb ou Ross, F (4,06%)		
33	Peso do frango na 2ª semana, Médio (467,7g), M	-0,7	14.480,00
34*	Peso do frango na 2ª semana, Superior (508g), M		
36	Peso do frango na 3ª semana, Médio (922,5g), M	-0,71	14.687,00
37*	Peso do frango na 3ª semana, Superior (1010g), M		
	Peso do frango na 2ª e 3ª semana, Médio, M	-1,11	22.755,00
39*	Peso do frango na 2ª e 3ª semana, Superior, M		

Quadro 6 – Principais cenários produtivos simulados e a estimativa do seu impacto financeiro na comparação com o cenário normal (médio) encontrado na empresa.

(conclusão)

Cenário produtivo simulado		¹ Diferença	Impacto financeiro (R\$)
ID	Variáveis alteradas		
CONDENAÇÃO TOTAL DE CARCAÇAS (%)			
41a	Média mortalidade na 1 ^a (0,74%), 2 ^a (1,15%) e 3 ^a (1,70%) semanas, F	-0,0795	8.347,00
48*	Baixa mortalidade na 1 ^a (0,09%), 2 ^a (0,62%) e 3 ^a (0,97%) semanas, F		
41a	Média mortalidade na 1 ^a (0,74%), 2 ^a (1,15%) e 3 ^a (1,70%) semanas, F	0,9405	-98.752,50
50*	Máxima mortalidade na 1 ^a (2,16%), 2 ^a (4,45%) e 3 ^a (4,06) semanas, F		
51	Peso do frango na 2 ^a semana, Médio (467,6 g), M	-0,0636	6.677,60
52*	Peso do frango na 2 ^a semana, Superior (508g), M		

* Cenário produtivo associado ao impacto financeiro estimado. M = macho; F = fêmea.

¹ Diferença observada entre os cenários comparados em relação aos valores obtidos de eclosão vendável, peso do frango ao final da quinta semana, condenação parcial ou condenação total.

Fonte: o próprio autor.

Traçando possíveis cenários e analisando os resultados oriundos das simulações, podem-se utilizar os modelos preditivos como uma ferramenta de gestão para tomada de decisão. À luz do potencial de perda ou ganho de receita (risco econômico), a empresa pode por sua vez adotar estratégias que minimizem o impacto negativo de determinados cenários de ocorrência frequente. Por exemplo, ao analisar e verificar o melhor desempenho da incubadora CASP[®] no parâmetro de produção “eclosão vendável”, em comparação com a Petersime[®] (cenários 1 a 8), o empresário ou administrador tem um critério objetivo para decidir qual marca é a melhor opção de compra. E isso é um ponto chave, porque sabe de antemão qual equipamento terá desempenho superior dentro da sua realidade, e não a partir de análises e parâmetros obtidos em outro contexto de produção - diferente do seu. Outros exemplos de estratégias possíveis frente a cenários desfavoráveis: investir na compra de novas vacinas para o seu programa de vacinação, adquirir equipamentos que potencializem o desempenho dos animais, implementar novo programa de treinamento para seus funcionários e integrados, revisar práticas de manejo, entre outras medidas. Estratégias deste tipo podem,

em um curto espaço de tempo, oportunizar à indústria avícola a obtenção de ganhos financeiros exponenciais.

Os modelos criados, a partir da base de dados compartilhada pela empresa parceira neste trabalho, não podem ser utilizados em outros estabelecimentos, porque cada empresa apresenta um contexto de produção único, que jamais se repete. Cada indústria ou segmento avícola deve construir seus próprios modelos de redes, buscando aqueles que melhor se ajustam. Sendo assim, os resultados encontrados nas projeções deste trabalho não podem ser generalizados, ficando a discussão dos dados restrita ao banco de dados analisado.

A criação de modelos matemáticos ajustados, que de fato reflitam a realidade de determinada empresa, necessariamente passa pelo correto registro dos dados. Sendo assim, faz-se necessária a capacitação contínua daquelas pessoas diretamente envolvidas no processo, para fins de padronização dos procedimentos. Na análise do banco de dados utilizada neste trabalho foi possível identificar diversos erros nos registros, tanto na forma quanto na escrita das informações, ou mesmo a ausência deles. Tal situação remete à ideia de que as pessoas ainda fazem pouco proveito dos dados que possuem, ou pior, arquivam as informações de forma arbitrária, sem uma análise mais profunda.

É importante salientar que a gestão das atividades por meio dos modelos de redes neurais artificiais em nada interfere na rotina normal da empresa, uma vez que se utilizam os dados que normalmente já são coletados. O que talvez possa ser alterada, em determinadas situações, é a maneira de se registrar. Planilhas digitais padronizadas aceleram o processo de análise dos dados e permitem a realização de projeções em um curto período de tempo – quase em tempo real.

O presente trabalho tem como grande diferencial a simulação de cenários produtivos a partir de modelos matemáticos construídos com variáveis que contemplam diferentes elos da cadeia de produção avícola: reprodutoras pesadas, incubatório, frango de corte e matadouro-frigorífico. E isso é extremamente importante em modelos preditivos, pois a inclusão de diversos indicadores produtivos incorpora ao modelo o efeito (variabilidade) de outras variáveis não controladas, aumentando o seu poder de generalização.

O treinamento dos quatro modelos de redes neurais foi realizado por meio do método genético, o que implica na limitação de se fazer projeções somente a partir de valores que se encontram dentro do intervalo entre a máxima e a mínima de cada variável que compõe a série histórica em análise. Por exemplo, se a máxima taxa de eclosão vendável registrada na empresa foi de 90%, não é possível criar cenários simulatórios com valores superiores a este. Mas isto está longe de ser uma limitação para o uso da ferramenta, uma vez que pouco

interessa para a empresa fazer simulações fora da sua realidade. E se houver interesse, uma alternativa é treinar os modelos através do método neural, o qual constrói modelos com maior grau de generalização, por aumentar dinamicamente o número de neurônios da camada oculta. A desvantagem deste último é que os modelos criados geralmente são menos ajustados, reduzindo a confiança sobre os valores preditos.

Entende-se por modelos de RNA ajustados aqueles que após as etapas de treinamento e validação apresentam os maiores valores de coeficiente de determinação múltipla, de coeficiente de correlação e os menores de erro (erro médio, erro quadrático médio e raiz do erro quadrático médio). Conforme ilustrado nas Tabelas 7 e 8 e nas Figuras 5, 6, 7 e 8, os modelos criados mostraram excelente nível de ajuste, o que confere grande confiabilidade aos valores projetados pelos cenários produtivos simulados neste estudo.

Métodos estatísticos convencionais por vezes não são capazes de explicar determinados fenômenos biológicos, porque possuem limitada capacidade de análise das interações entre as diversas variáveis que compõem o sistema de produção avícola. E as redes neurais vêm para preencher esta lacuna.

Pelos trabalhos já realizados até o momento, incluindo este, pode-se afirmar que a modelagem matemática por meio de RNA apresenta grande potencial de aplicação na avicultura industrial. Sendo assim, faz-se necessário que os veterinários se apoderem desta ferramenta de apoio. Ao passo que todo profissional é pago para tomar decisões, fazer escolhas tendo maior garantia de acerto, ou menor probabilidade de erro, aumentam sua capacidade de trabalho e credibilidade.

Acredita-se que ao incorporar essas novas tecnologias de informação, a avicultura brasileira gozará de um salto de produtividade em seu sistema de produção e de melhoria da qualidade sanitária dos seus produtos destinados aos mercados nacional e internacional.

5 CONCLUSÕES

Além de possibilitar a predição dos valores de parâmetros de produção importantes dentro do sistema de integração avícola proposto (reprodutoras pesadas, incubatório, frango de corte e matadouro-frigorífico), os modelos de RNA gerados para as variáveis eclosão vendável, peso do frango ao final da quinta semana, condenação parcial e condenação total de carcaças também permitiram a realização de simulações de cenários produtivos.

A simulação de cenários produtivos hipotéticos permitiu mensurar o efeito das variáveis que compuseram cada um dos quatro modelos de RNA construídos e o potencial de impacto financeiro que podem provocar frente a situações de melhor ou pior desempenho produtivo.

REFERÊNCIAS

- ABIODUN, O. I. *et al.* State-of-the-art in artificial neural network applications: a survey. **Heliyon**, vol. 4, p. 1-41, 2018.
- ABPA – Associação Brasileira de Proteína Animal. **Relatório Anual 2019**, p. 9-47. Disponível em: <http://cleandrodias.com.br/wp-content/uploads/2019/05/RELATO%C3%ACRIO-ANUAL-ABPA-2019.pdf>. Acessado em: 14 de novembro de 2019, às 20:10 hs.
- AVISITE – o portal da avicultura na internet. **Estatísticas e preços**. Disponível em: <https://www.avisite.com.br/index.php?page=estatisticaseprecos&acao=exportacao>. Acessado em: 16 de novembro de 2019, às 22:29 hs.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Redes Neurais Artificiais – teoria e aplicações**, 2ª edição: Editora LTC, 2007, 226 p.
- DAVE, V. S.; DUTTA, K. Neural network-based models for software effort estimation: a review, **Artificial Intelligence Review**, vol. 42, n. 2, p. 295-307, 2014.
- DEY, B. P.; CHEN, Y. R.; HSIEH, C.; CHAN, D. E. Detection of septicemia in chicken livers by spectroscopy. **Poultry Science**, v. 82, n. 2, p. 199-206, 2003.
- FAHLMAN, S. E. The Recurrent Cascade-Correlation Architecture. *In: Advances in Neural Information Processing Systems 3*, D. S. Touretzky (ed.), Morgan Kaufmann, Los Altos CA, p. 190-196, 1991.
- HAYKIN, S. **Redes Neurais – princípios e práticas**. 2ª edição, Porto Alegre, Editora Bookman, 2001, 899 p.
- KOVÁCS, Z. L. **Redes Neurais Artificiais: fundamentos e aplicações**. 2ª edição, São Paulo. Edição Acadêmica, 1996, 163 p.
- LUIDWIG JUNIOR, O.; MONTGOMERY, E. **Redes Neurais – Fundamentos e Aplicações com programas em C**. Editora Ciência Moderna, 2007, p. 125.
- MCCLELLAN, J. L.; RUMELHART, D. E. **Parallel Distributed Processing: Explorations in the Microstructure of Cognition – Foundations**. Editora A Bradford book, vol. 1, 1987, 567 p.
- MEDEIROS, L. F. **Redes Neurais em Delphi**. 2ª edição: Editora Visual Books, 2006, 210 p.
- MORAES, L. B. *et al.* Evaluation of follicular lymphoid depletion in the Bursa of Fabricius: An alternative methodology using digital image analysis and artificial neural networks. **Pesquisa Veterinária Brasileira**, vol. 30, n. 4, p. 340-344, 2010.
- PINTO, P. R. Uso de Redes Neurais Artificiais no gerenciamento de matadouros-frigoríficos de aves e suínos no Sul do Brasil. 2006. 76 f. **Dissertação** (Mestrado em Ciências Veterinárias). Universidade Federal do Rio Grande do Sul, Porto Alegre, 2006.

REALI, E. H. Utilização de redes inteligência artificial no gerenciamento da produção de frangos de corte. 2004. 127 f. **Dissertação** (Mestrado em Ciência Veterinárias). Universidade Federal do Rio Grande do Sul, Porto Alegre, 2004.

ROCHA, A. C. G. P. Utilização de Inteligência artificial (redes neurais artificiais) para classificação de patogenicidade de amostras de *Escherichia coli* isoladas de frangos de corte. 2006. 115 f. **Tese** (Doutorado em Ciências Veterinárias), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2006.

ROUSH, W.B. *et al.* Probabilistic Neural Network prediction of ascites in broilers based on minimal invasive physiological factors. **Poultry Science**, vol. 76, p. 1513-1516, 1997.

SALLE, C. T. P. **Veterinarians are Paid to Make Decisions**. Approaches in Poultry, Dairy & Veterinary Sciences, vol. 3, n. 5, p. 1-2, 2018.

SALLE, C. T. P. *et al.* Use of Artificial Neural Networks to Estimate Production Parameters of Broiler Breeders in the Breeding Phase. **Brazilian Journal of Poultry Science**, Campinas Sept./Dec., vol. 3, n. 3, 2001.

SALLE, C. T. P. *et al.* Use of artificial neural networks to estimate production variables of broilers breeders in the production phase. **British Poultry Science**, vol. 44, n. 2, p. 211-217, 2003.

SALLE, F. O. Utilização de inteligência artificial (redes neurais artificiais) no gerenciamento do incubatório de uma empresa avícola do sul do Brasil. 2005. 82 f. **Dissertação** (Mestrado em Ciências Veterinárias), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2005.

SALLE, F.O. *et al.* Utilização de inteligência artificial (redes neurais artificiais) para a classificação do comportamento bioquímico de amostras de *Escherichia coli* isoladas de frangos de corte. **Acta Scientiae Veterinariae**, vol. 38, n. 1, p. 59-62, 2010.

SPOHR, A. Gerenciamento através de Redes Neurais Artificiais dos fenômenos que envolvem as atividades de produção de reprodutoras pesadas e do frango de corte, de um incubatório e de um abatedouro avícolas. 2011. 61 f. **Dissertação** (Mestrado em Ciências Veterinárias), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

TEJKOWSKI, T. M. Uso de redes neurais artificiais para classificação da patogenicidade de *Escherichia coli* de origem aviária. 2013. 64 f. **Dissertação** (Mestrado em Ciências Veterinárias). Universidade Federal do Rio Grande do Sul, Porto Alegre, 2013.

WANG, D.; HE, H.; LIU, D. Intelligent optimal control with critic learning for a nonlinear overhead crane system, **IEEE Transactions on Industrial Informatics**, vol. 14, n. 7, p. 2932-2940, 2018.