

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

**UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL (REDES NEURAIS
ARTIFICIAIS) NO GERENCIAMENTO DE REPRODUTORAS PESADAS**

**Adriano da Silva Guahyba.
Tese defendida como requisito para
obtenção do grau de Doutor em
Ciências Veterinárias na área de
Medicina Veterinária Preventiva,
especialidade Sanidade Avícola.
Orientador: Carlos Tadeu Pippi Salle.
Co-orientador: Vera Beatriz Wald.**

**Porto Alegre
2001**

DEDICATÓRIA

A Deus, Senhor de tudo o que existe.

À minha mãe, pilar de amor, dedicação e caráter.

Ao meu orientador, mescla de professor, guia e amigo.

AGRADECIMENTOS

- À toda minha família.
- À minha noiva, Simone Santos Lopes e à sua família.
- Ao meu padrinho (José Antônio Reimunde Martinez) e minha madrinha (Norma Gosch Wiesbauer).
- Aos Professores do Centro de Diagnóstico e Pesquisa em Patologia Aviária (CDPA), os quais iluminaram meu caminho nos quase dez anos em que desenvolvo meus estudos neste local: Prof. Dr. Carlos Tadeu Pippi Salle, Prof. Dr. Ari Bernardes da Silva, Prof. Dr. Vladimir Pinheiro do Nascimento, Prof. Hamilton Luiz de Souza Moraes (M.Sc.) e Prof. Dr. Cláudio Wageck Canal.
- À minha co-orientadora, Prof^a. Dra. Vera Beatriz Wald.
- Aos exemplos de pós-graduandos do CDPA em minha época de graduação: Álvaro Bavaresco, Gustavo Lorenzini, Marcus Sfoggia, Luciana dos Santos, Milene Cé, Ana Wendelstein, Aldemir Ribeiro, Nara Rodrigues, Luis Fallavena, Maristela Flores e aos meus grandes amigos Obiratã Rodrigues e Alexandre Pontes.
- Ao bolsista de iniciação científica e acadêmico de Medicina Veterinária, Fernando Pilotto, pelo auxílio sempre incondicional.
- Aos funcionários do CDPA: Luiz Henrique Carbone Ribas, Sílvio Luiz da Silveira Rocha (Biólogo) e Omar de Oliveira, pelo companheirismo e pelos momentos lúdicos.
- Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pelo financiamento das bolsas de estudo, durante a iniciação científica, mestrado e doutorado.

SUMÁRIO

	p.
LISTA DE TABELAS	005
LISTA DE FIGURAS	006
RESUMO	007
ABSTRACT	008
1 INTRODUÇÃO	009
1.1 Gerenciamento avícola - passado	012
1.2 Gerenciamento avícola - presente	013
2 REVISÃO BIBLIOGRÁFICA	015
2.1 Redes neurais artificiais	015
2.2 Utilização de redes neurais artificiais em outras áreas	017
2.3 Utilização de modelos matemáticos em veterinária (ênfase em avicultura)	020
2.4 Utilização de redes neurais artificiais em veterinária	025
3 MATERIAL E MÉTODO	027
3.1 Período de recria (1 - 25 semanas)	028
3.2 Período de produção (26 - 66 semanas)	028
3.3 Análise por redes neurais artificiais	029
4 RESULTADOS E DISCUSSÃO	032
4.1 Anotação dos dados na granja	032
4.2 Período de recria (1 - 25 semanas)	034
4.3 Período de produção (26 - 66 semanas)	040
4.4 Gerenciamento avícola - incursão ao futuro	048
5 CONCLUSÃO	051
ANEXO 1 - Análise gráfica dos dados de recria (antes e depois da eliminação de “outliers”)	052
ANEXO 2 - Contribuições, informações e gráficos das redes neurais artificiais geradas para o período de recria	056
ANEXO 3 - Análise gráfica dos dados de produção (antes e depois da eliminação de “outliers”)	061
ANEXO 4 - Contribuições, informações e gráficos das redes neurais artificiais geradas para o período de produção	071
BIBLIOGRAFIA CITADA	111

LISTA DE TABELAS

	p.
Tabela 1 Saídas (variáveis a serem preditas), número de modelos (redes) gerados para o período de recria e o QME e o R^2 dos modelos escolhidos.....	034
Tabela 2 Informações das redes neurais artificiais construídas para a saída “peso das aves na semana seguinte”.....	035
Tabela 3 Saídas (variáveis a serem preditas), número de modelos (redes) gerados para o período de produção e o QME e o R^2 dos modelos escolhidos.....	041
Tabela 4 Informações das redes neurais artificiais construídas para a saída “ovos produzidos na semana seguinte”.....	042

LISTA DE FIGURAS

	p.
Figura 1 Arquitetura da rede neural artificial de retropropagação utilizada.....	030
Figura 2 Gráfico de dispersão da Predição <i>versus</i> Predição - Real do modelo escolhido para a saída “peso das aves na semana seguinte”.....	036
Figura 3 Contribuições das diferentes entradas na saída “peso das aves na semana seguinte”.....	037
Figura 4 Contribuições das diferentes entradas na saída “mortalidade acumulada das fêmeas”.....	038
Figura 5 Planilha eletrônica para a simulação do arraçamento dos animais e seu reflexo no peso da semana seguinte.....	040
Figura 6 Contribuições das diferentes entradas na saída “ovos a serem produzidos na semana seguinte”.....	043
Figura 7 Contribuições das diferentes entradas na saída “mortalidade acumulada das fêmeas”.....	044
Figura 8 Planilha eletrônica para verificar o desempenho do lote.....	045
Figura 9 Planilha eletrônica para a simulação da produção de ovos na semana seguinte a partir da quantidade de ração fornecida às aves na semana atual.....	045
Figura 10 Planilha eletrônica para a simulação da quantidade de pintos produzidos a partir de certa quantidade de ovos incubados.....	046

RESUMO

Uma atividade com a magnitude da avicultura, que usa equipamentos de última geração e serviços atualizados, é levada, na maioria dos casos, a tomar decisões que envolvem todos aspectos de produção, apoiada em critérios subjetivos. A presente tese objetivou estudar a utilização das redes neurais artificiais na estimação dos parâmetros de desempenho de matrizes pesadas, pertencentes a uma integração avícola sul-brasileira. Foram utilizados os registros de 11 lotes em recria, do período compreendido entre 09/11/97 a 10/01/99 e de 21 lotes em produção, do período compreendido entre 26/04/98 a 19/12/99, para a análise por redes neurais artificiais. Os dados utilizados corresponderam a 273 linhas de registros semanais, do período de recria e 689 linhas de registros semanais, do período de produção. Os modelos de redes neurais foram comparados e selecionados como melhores, baseados no coeficiente de determinação múltipla (R^2), Quadrado Médio do Erro (QME), bem como pela análise de gráficos, plotando a predição da rede *versus* a predição menos o real (resíduo). Com esta tese foi possível explicar os parâmetros de desempenho de matrizes pesadas, através da utilização de redes neurais artificiais. A técnica permite a tomada de decisões por parte do corpo técnico, baseadas em critérios objetivos obtidos cientificamente. Além disso, este método permite simulações das conseqüências de tais decisões e fornece a percentagem de contribuição de cada variável no fenômeno em estudo.

ABSTRACT

An economic activity with the magnitude of the poultry industry, which uses top line equipment and services, generally is lead to make decisions involving all production parameters, based in subjective criteria. The aim of this paper is to study the use of artificial neural networks to estimate performance parameters in broiler breeders, belonging to a South Brazilian poultry farm. Data from 11 breeding flocks was recorded between 9th of November, 1997 and 10th of January, 1999 and from 21 broiler production breeder flocks, between 26th of April, 1998 and 19th of December, 1999. The data used corresponds to 273 data lines from the breeding phase and 689 data lines from the production phase, obtained from weekly recordings. Artificial neural networks processed these datas. The artificial neural network models that were generated were compared and selected based on its determination coefficient (R^2), Mean Squared Error (MSE), and by graphical analysis of the plot of network predictions *versus* the predictions minus the actual data (residue). The authors conclude that it is possible to explain the performance parameters of broiler breeders, with the use of artificial neural networks. The method allows the decision making by the technical staff to be based on objective criteria, obtained scientifically. Besides that, this method allows simulation of the consequences of these decisions, and estimates the contribution of each variable used in the phenomenon under study.

1 INTRODUÇÃO

Alguns dados (fornecidos pela Associação Gaúcha de Avicultura/ASGAV) demonstram a importância da avicultura para o Estado do Rio Grande do Sul. No Estado existem 16 frigoríficos com Inspeção Federal e 12 com Inspeção Estadual. Toda a estrutura que envolve a avicultura é responsável por 40 mil empregos diretos e 780 mil indiretos; 10 mil produtores integrados, com um plantel permanente de 60 milhões de pintos de corte e 25 milhões de avós/matrizes/poedeiras comerciais. No ano de 2000, a avicultura gaúcha alojou 544 milhões de pintos e abateu 516 milhões de aves, produzindo um total de 876,7 mil toneladas de carne (666 mil toneladas para o mercado brasileiro). O faturamento no ano de 2000 foi de R\$968.500.000,00, sendo que o valor relacionado à exportação foi de US\$190.400.000,00 (em torno de 210.399 toneladas exportadas). No ano de 2000, o Rio Grande do Sul participou com 15,33% da comercialização brasileira. Em comparação com outros estados, ficou em 2º lugar no quesito número de aves abatidas e em 2º lugar em toneladas produzidas. Entre as dez maiores empresas avícolas nacionais, estão no nosso estado a Avipal S/A Avícola e Agropecuária, a Companhia Minuano de Alimentos, a Cooperativa R. A. Languiru, a Doux Frangosul S/A, a Perdigão Agro-industrial S/A e a Predileto Pena Branca Alimentos do Sul S/A. Estes dados servem para ilustrar a importância do mercado avícola, praticamente estabelecido em todas as áreas do estado. A postura comercial é representada por 148 empresas e 180 mini e pequenos produtores, sendo que 4 empresas possuem incubatórios independentes. No ano, a produção de ovos comerciais foi de 3 milhões e 300 mil caixas com 30 dúzias, com um faturamento de

R\$60.000.000,00. O consumo de insumos básicos foi de 2 milhões toneladas de milho e 700 mil toneladas de farelo de soja.

Ainda deve ser acrescentado, que a avicultura, pela sua característica associativista, integra os pequenos produtores ao processo produtivo, assegurando-lhes tecnologia de ponta, capital de giro e garantia de comercialização do produto, tornando viável o minifúndio e fazendo com que o produtor rural se fixe no campo e não engrosse os cinturões de miséria das grandes cidades.

Uma atividade com esta magnitude ainda apresenta algumas distorções, até certo ponto paradoxais. A mesma avicultura que usa equipamentos de última geração e serviços atualizados, responsáveis pela competitividade internacional do produto brasileiro, na maioria dos casos é levada a tomar decisões que envolvem todos os aspectos de produção, apoiada em critérios subjetivos. Como critério subjetivo, deve ser entendida a análise meramente gráfica dos dados e uma experiência empírica, que se traduz por sensação "epidérmica" de erro e acerto. Uma atividade tão importante econômica e socialmente, necessita de critérios objetivos, fundamentados cientificamente, para dar sustentação às decisões que objetivarão a melhoria da produtividade dos plantéis e da qualidade sanitária do produto oferecido aos mercados externo e interno.

Segundo Rivas (1994), as bases e os fundamentos da modelagem matemática são, infelizmente, pouco conhecidos e pouco acessíveis aos profissionais não especializados, devido à escassez de livros texto e de artigos de divulgação. Benigni & Giuliani (1994) também comentaram o fato de que a modelagem matemática ainda permanece fora do domínio da maioria dos profissionais da área biológica e que não é fácil identificar todas as razões para esta situação mas, certamente, há razões históricas para a forma com que os diferentes campos da ciência foram divididos, sendo que esta divisão perpetuou-se até hoje nas instituições educacionais e científicas. Os autores ainda afirmaram, que junto a este problema, a biologia apresenta um grande número de peculiaridades que tornam difícil o uso imediato das mesmas ferramentas usadas em ciências exatas. A modelagem, através de leis naturais, típicas da física, é baseada em um número de exigências que raramente são satisfeitas em biologia. Os mesmos autores citam as particularmente importantes: 1)

Prévia identificação dos objetos que tenham um papel no fenômeno sob estudo e 2) Identificação das condições limitantes e do domínio da aplicabilidade do modelo.

Concordamos em parte com tais afirmações, visto que há um enorme aparato de conhecimento, textos e ferramentas disponíveis não só ao meio acadêmico mas para qualquer pessoa que tiver acesso à internet e interesse em estudar as bases e fundamentos da modelagem matemática. A modelagem matemática em biologia é difícil, mas não impossível. É possível atestar isto, ao verificar a extensa bibliografia disponível, que descreve os mais diversos métodos matemáticos utilizados por pesquisadores para explicar fenômenos biológicos.

Nas empresas avícolas, não só nas brasileiras, mas em todo o mundo, há uma grande quantidade de dados gerados com o intuito de conhecer e melhorar a qualidade do produto final. A avicultura demonstrou competência e sempre esteve aberta às inovações, razões que a levaram à posição de destaque em que se encontra atualmente. Esta situação invejável deixa-a no compromisso de buscar, constantemente, novas alternativas e patamares de conhecimento. Para tal, é importante diagnosticar os pontos de estrangulamento ou gargalos que prejudicam o desempenho produtivo. Um deles, muito importante, é a infinidade de registros que são gerados dentro das empresas. Tanto aqui quanto no exterior, estes dados não são, em sua maioria, analisados adequadamente, causando a falta de critérios que orientariam as decisões empresariais. Ora, sem critérios claros não podem haver decisões firmes e fundamentadas. Na verdade, os registros dos dados da avicultura traduzem numericamente os fatos que compõem a história da empresa. Esta história deve ser compreendida para que origine parâmetros que orientarão as decisões dos empresários e dos profissionais e os levem ao êxito do empreendimento pretendido. Quem não gostaria de saber, por antecipação, a ocorrência de algum fato relevante na produção ou sanidade dos seus plantéis? Seria interessante conhecer, com segurança, as contribuições que os vários setores de uma companhia têm sobre um produto final? Interessaria ao empresário avícola fazer simulações com as decisões que poderia tomar em uma determinada situação e medir os reflexos que terão na empresa que dirige? Seria bem recebida pelo profissional que trabalha na avicultura a comprovação objetiva, numérica, das medidas que ele proponha ou venha a recomendar? Quem não gostaria de saber o grau de eficácia do trabalho realizado?

Interessaria ao profissional dispor de programas de monitorização ou de verificação da qualidade, que lhe gerassem dados que fossem interpretados objetivamente e tivessem sustentação científica? Por outro lado, o pouco conhecimento dos registros de produtividade acumulados ou a análise inadequada dos seus resultados, leva o dirigente a erros, com maior ou menor repercussão, os quais, de outra forma, seriam facilmente evitáveis. É preciso buscar técnicas que informem o quanto cada variável está influenciando num fenômeno em estudo. Desta forma, é possível priorizar as soluções corretivas dos problemas detectados. Primeiro atacam-se os principais (ajuste macro) e depois de sanados estes, resolvem-se os que têm menor contribuição (ajuste micro).

1.1 Gerenciamento avícola - passado

Documentos históricos registram o início da criação de aves da raça New Hampshire no Brasil, em 1947, pela Granja São João, instalada em São Paulo. Até chegar ao peso de 1,6kg, o ciclo das aves era de 14 semanas e a conversão alimentar era de 3,5. De um modo geral, os índices zootécnicos não satisfaziam aos avicultores, sobretudo diante dos crescentes preços das rações. Era efetivamente o nascimento da avicultura industrial no Brasil e no mundo. O verdadeiro divisor de águas na história da criação mundial de aves veio a acontecer durante a II Guerra Mundial. Até então, a atividade era empreendida de maneira simples e artesanal, com poucos conhecimentos técnicos, que raramente chegavam à aplicação prática. A necessidade imediata de abastecer as tropas na frente de batalha trouxe enormes benefícios para a avicultura, privilegiada com grandes somas de recursos para pesquisa e desenvolvimento. Com as novas linhagens surgiam rações específicas, medicamentos preventivos e outros progressos. Enquanto isso, os criadouros iam se multiplicando e disseminando-se com grande velocidade nos Estados Unidos e na Europa, utilizando os recursos mais modernos da época (Pinazza & Lauandos, 2000). Segundo o Prof. Ari Bernardes da Silva (Fac. Vet. – UFRGS, comunicação verbal), a raça New Hampshire era de duplo propósito (ovos e carne). Naquela época, no RS, criavam-se os machos para o abate e as fêmeas para postura.

A avicultura passou por profundas transformações produtivas ao longo desta história, sempre com a característica de vanguarda tecnológica do setor agropecuário. Obteve um desenvolvimento sem precedentes nos últimos 40 anos. Este crescimento veio acompanhado de imensas transformações nas áreas de nutrição, genética, manejo e sanidade. Tal aporte tecnológico foi avidamente incorporado pelos empresários avícolas, promovendo a transformação da "criação de galinhas" no agronegócio avícola dos dias atuais. Resumindo, o avicultor saiu do quintal para alcançar as bolsas de valores. Enfim, a avicultura cresceu muito. Cresceu tanto que preocupou os competidores nacionais e internacionais. Todos os dias ouve-se falar da OMC (Organização Mundial de Comércio), subsídios e barreiras sanitárias. Estas últimas têm se constituído no meio mais usado para criar dificuldades no comércio internacional. Em um futuro muito próximo, dadas às características continentais do Brasil, as barreiras sanitárias poderão ser empregadas para proteger os interesses da indústria avícola nos diferentes estados da federação.

1.2 Gerenciamento avícola - presente

A avicultura acostumou-se a lidar com itens como "custo/benefício", "gestão de qualidade ou qualidade total". Nos gabinetes dos diretores é possível visualizar preceitos modernos de administração como, por exemplo, o ciclo tão aceito do "planejar - fazer - controlar - ajustar". Na estrutura de produção tudo é registrado e guardado. Antigamente, usavam-se planilhas de papel e os documentos gerados eram mantidos em arquivos, mas, nos dias de hoje, o computador faz parte das rotinas e os dados são guardados magneticamente.

Apesar de todo o desenvolvimento, muitas decisões ainda são tomadas sem uma verdadeira análise objetiva do processo. Dessa forma, essas decisões correm o risco de tornarem-se meros palpites sem embasamento científico e tecnológico. Muitos técnicos de campo tomam decisões tendo como base comparativa, médias de dados, as quais, isoladamente, não possibilitam uma interpretação científica. É necessária uma análise matemática mais aprofundada no assunto que se está estudando.

Hoje em dia, apesar de todos os avanços ocorridos na avicultura, ainda se realiza o arraçamento das aves de forma pouco precisa. A maioria dos técnicos se baseia em tabelas adquiridas através dos fornecedores das linhagens, o que deveria ser feito com cuidado, já que as linhagens de corte são selecionadas e testadas fora de nosso País, portanto, fora de nossa realidade climática, sanitária e de manejo. O curioso é que os mesmos técnicos que utilizam estas tabelas concordam que elas devem sofrer adaptações, pois as quantidades de ração fornecidas por eles diferem muito daquelas recomendadas nas tabelas de arraçamento.

A grande quantidade de empresas com múltiplos lotes de aves tem demandado sistemas de registro informatizados mais rápidos e compreensíveis. Técnicos precisam tomar decisões diárias baseadas no desempenho do lote e em condições ambientais do dia. Eles não podem esperar por resumos semanais.

Infelizmente, modelos matemáticos raramente são utilizados diretamente por produtores. São poucos os exemplos que podemos citar quanto a análises mais aprofundadas a respeito do gerenciamento procedido a campo.

A presente tese objetiva demonstrar a possibilidade de uso da metodologia de redes neurais artificiais na estimação de parâmetros de produção de galinhas reprodutoras pesadas, usando como exemplo um conjunto de dados de uma integração avícola sul-brasileira.

2 REVISÃO BIBLIOGRÁFICA

Segundo North & Bell (1990), fêmeas matrizes de corte, possuem a habilidade inerente de crescer rápido. Durante o período de crescimento, quando alimentadas à vontade, elas ganham peso excessivo e depositam muita gordura interna. O controle do peso deve ser feito em todo o período de recria e não somente poucas semanas antes do início da postura. Eles também ressaltam a importância de se alimentar os galos de forma correta pois, caso fiquem obesos, poderão desenvolver problemas articulares, que os tornarão menos aptos à reprodução.

Sendo o peso das aves um determinante do futuro (e/ou presente) desempenho produtivo, é de suma importância que o técnico possua o controle sobre este parâmetro nos períodos de recria, bem como no período de produção, atentando também neste período, para a produção de ovos, sua incubabilidade e eclosão.

2.1 Redes neurais artificiais

Rosenblatt, em 1958, já descreveu um modelo computacional probabilístico para descrever a organização e o estoque de informação no cérebro humano, o qual batizou de Perceptron que, na verdade, era um modelo de rede neural artificial.

As redes neurais foram inspiradas na estrutura e na função de neurônios biológicos. Redes neurais aprendem com a interação de padrões de exemplo, sem requererem *a priori* um conhecimento das relações entre as variáveis sob investigação. O neurônio recebe uma ou mais entradas e transforma a soma daquelas entradas em um valor de saída, o qual é transferido para outros neurônios. A rede

neural artificial é um conjunto de unidades processadoras (ou nódulos) que simulam neurônios biológicos e são interconectados por um conjunto de pesos (análogo às conexões sinápticas no sistema nervoso), o qual permite tanto processamento serial quanto paralelo de informação através da rede (Astion & Wilding, 1992; Roush *et al.*, 1996; Xin, 1999). Os "neurônios" da rede podem receber entradas excitatórias ou inibitórias de outros neurônios (Forsström & Dalton, 1995) e produzem uma saída, que geralmente é uma função não linear da entrada da rede (Astion & Wilding, 1992). Em contraste com muitos sistemas especialistas, as redes neurais artificiais não dependem de algoritmos pré-definidos (Lee *et al.*, 1999).

Fenômenos complexos são aqueles que envolvem variáveis conhecidas como causalmente dependentes, mas cuja dependência está muito além de uma simples relação linear ou não linear do tipo polinomial de primeira ordem. Fenômenos complexos têm sido área fértil para o desenvolvimento de modelos com redes neurais. Redes neurais, mesmo que implementadas com sucesso, permitem apenas simular ou emular o fenômeno modelado, não oferecendo por si só a possibilidade de se simplificar, generalizar ou reduzir a teoria por trás do fenômeno complexo. Neste sentido, podem ser consideradas como uma panacéia pragmática que funciona, mas não se sabe porquê (Kovács, 1996).

Além de concordar com o supra citado, Forsström & Dalton (1995) afirmaram que à medida que o aprendizado ocorre, o erro entre a saída da rede e a saída desejada diminui. Então, o conhecimento, o qual a rede aprende, está codificado nos pesos das conexões entre neurônios. Devido ao fato de tal conhecimento estar distribuído através dos pesos, é quase impossível interpretar (no sentido de "dissecar") o conhecimento, o qual foi aprendido por qualquer rede de retropropagação. Este é o motivo pelo qual as redes neurais são freqüentemente chamadas de "caixas pretas". Elas aprendem a calcular uma saída corretamente a partir de um padrão de entrada, mas elas raramente revelam, sob qualquer forma inteligível, o conhecimento que está por trás dos seus julgamentos.

Vantagens das redes neurais artificiais:

- os cálculos são feitos em neurônios individuais;
- permitem execução de tarefas muito mais complexas para serem aprendidas de exemplos de dados, do que técnicas de estatística convencional;

- dados qualitativos e quantitativos facilmente podem ser incluídos no mesmo modelo;

- já que os dados usados na rede não têm que ir ao encontro de quaisquer suposições de distribuição de dados, não se exige homocedasticidade e, portanto, não há necessidade de transformação de dados, como é necessário em algumas ocasiões, quando estatística é utilizada;

- são particularmente ajustadas à análise de dados não lineares e multivariados e, como é sabido, a maioria dos fenômenos biológicos não se comporta de forma linear, ou seja, como uma simples reta (devido à enorme complexidade e inter-relação entre quaisquer variáveis sob estudo).

Desvantagens das redes neurais artificiais:

- o conhecimento aprendido não pode ser expresso em regras, ou seja, não existe uma equação inteligível que possa ser mostrada;

- a validação da rede é mais difícil do que em estatística convencional;

- as redes neurais precisam de muitos exemplos para serem adequadamente treinadas e validadas.

2.2 Utilização de redes neurais artificiais em outras áreas

Há muito tempo, redes neurais são usadas com o objetivo de classificar e reconhecer padrões: reconhecer e gerar fala; prever índices financeiros, tais como taxas de câmbio de moedas; localizar a origem de pontos no radar; otimizar processos químicos; reconhecer alvos e detectar minas bélicas; identificar células cancerosas; reconhecer anormalidades cromossômicas; detectar fibrilação ventricular; prever trajetórias de reentrada de naves espaciais; reconhecer automaticamente caracteres escritos a mão; sexar rostos, entre outros (Cheng & Titterington, 1994).

Originalmente usadas na indústria militar, as redes neurais artificiais têm seu uso crescente em bancos, principalmente quando se fala de cartões de crédito e, especificamente, de comércio eletrônico (via internet), como método para evitar fraudes eletrônicas nestas operações (O'Sullivan, 1999; Estock, 1999). As redes neurais reconhecem padrões específicos de comportamento de gastos do proprietário

do cartão de crédito, aprendem a partir de suas experiências passadas, e podem ser retreinadas, adaptando-se a uma situação específica.

Bruno (1999) fez a propaganda de um produto, o qual utilizam, dentre outras técnicas, redes neurais artificiais para interagir com os clientes de bancos quando na requisição de financiamentos e/ou outros serviços realizados em tempo real, via internet.

Uysal & El Roubi (1999) compararam o uso de redes neurais artificiais e regressão múltipla para análise de demanda em turismo. Em seu estudo, os resultados revelaram que o uso de redes neurais artificiais tem melhores estimativas em termos de predição e acurácia. Goodman (1999) também comparou, redes neurais artificiais e métodos estatísticos e concluiu que um novo caminho promissor de pesquisa é o desenvolvimento de modelos biologicamente reais que possuam as vantagens das atuais RNAs, adicionados de habilidades de reconhecimento de padrões.

Na medicina humana, as redes neurais artificiais são amplamente utilizadas. Cross *et al.* (1995) afirmaram que há campo para o desenvolvimento de ferramentas decisórias, as quais poderiam ajudar médicos menos experientes, fornecendo-lhes conhecimento alicerçado em um grande número de casos, sendo que estes poderiam formar uma "memória" de casos, os quais não seriam afetados pela troca de pessoal. O mecanismo para tomada de decisão em tais suportes diagnósticos pode ser qualquer forma de sistema estatístico ou baseado em regras que forneçam a melhor solução para um problema particular. Os autores exploram o assunto, sugerindo que redes neurais terão um papel importante no suporte decisório em um futuro próximo. Forsström & Dalton (1995) abordaram o uso de redes neurais artificiais como ferramentas em medicina clínica, enfatizando o importante papel deste método em análise por imagens, processamento de sinais e medicina laboratorial.

Dybowski & Gant (1995) também exploraram o uso de redes neurais artificiais em patologia e laboratórios médicos. Segundo eles, a tecnologia de rede neural é perfeitamente ajustada à natureza, freqüentemente complexa de amostras patológicas. Os autores fizeram um exercício de prospecção quanto às aplicações futuras, que podem incluir a detecção de características anormais em biópsias de tecidos e a interpretação de citogramas de fluxo, a partir de amostras clínicas de urina. A aplicação de redes neurais em medicina laboratorial e patologia também foi

discutida por Astion & Wilding, em 1992, os quais concluíram que laboratoristas clínicos estão em uma posição ideal para explorar as redes neurais, visto que eles têm acesso a grandes quantidades de dados de pacientes em computadores. Estes dados são fonte potencial e altamente qualificada de ocorrências, que podem ser utilizadas para o treinamento das redes.

No trabalho de Callan *et al.* (1999), foram aplicadas redes neurais para avaliar testes audiológicos usados para prever patologia retrococlear, pesando diferentemente os resultados da bateria de testes. Os autores acreditam que as redes neurais podem ajudar a concluir se os testes predizem acuradamente, informam as contribuições independentes de testes múltiplos, predizem o mesmo resultado e indicam como combinar os testes múltiplos para um diagnóstico preciso.

Kirby *et al.* (1999) realizaram estudo retrospectivo, analisando uma rede neural para substituir a polissonografia no diagnóstico de apnéia obstrutiva do sono. Concluíram que a rede neural, desde que treinada apropriadamente, tem a habilidade de classificar acuradamente, a partir de dados clínicos, pacientes com esta doença. Um detalhe importante é que a rede, ao executar a classificação, não misturou pacientes apresentando doença moderada com severa. A partir daquele estudo, também concluíram que o uso da rede neural poderia ter reduzido o número de polissonografias, mas é necessária uma validação prospectiva da rede neural para o diagnóstico da apnéia obstrutiva do sono.

Lee *et al.* (1999) treinaram uma rede neural artificial recorrente com retropropagação da camada oculta e o desempenho foi comparado com vários sistemas convencionais de detecção de anomalia no padrão de taxa cardíaca fetal humana. Depois de ajustados os parâmetros, as redes neurais testadas tiveram um desempenho melhor do que os sistemas convencionais.

Tholudur & Ramirez (1999), verificaram e validaram experimentalmente uma rede neural para modelar sistemas dinâmicos. O sistema experimental sob consideração foi o sistema vetor-hospedeiro de *Escherichia coli* D1210 e o plasmídeo pSD8, o qual produz a proteína β -galactosidase sob o efeito do indutor IPTG. Foram obtidas condições operacionais ótimas, sendo que o modelo baseado em rede neural predisse melhor a dinâmica de produção de proteína do que os modelos fundamentalmente cinéticos, propostos anteriormente.

2.3 Utilização de modelos matemáticos em veterinária (ênfase em avicultura)

Chesini, em 1989, já atentou para a importância dos custos de produção no processo produtivo avícola. Porém, o autor não aprofundou a discussão de como fazer isto.

Abaixo estão citados alguns registros da literatura, os quais demonstram análises mais aprofundadas a respeito do gerenciamento procedido a campo.

Franco (1996), comparou o custo de produção dos 25% piores lotes *versus* os 25% melhores lotes de uma integração avícola. Naquele ano, o autor obteve uma diferença de 2,7% no custo de produção favorável aos melhores resultados, ou seja, para cada 1 milhão de aves abatidas com 2,5kg de peso, o autor calculou uma economia de R\$50.000,00, se conseguisse os índices técnicos obtidos pelos 25% melhores (dados da época). Morris (1995), também realizou cálculos demonstrando os custos de prevenção e controle de doenças avícolas. O autor concluiu que tais custos são muito menores do que os possíveis prejuízos ocasionados por eventuais doenças.

Lima & Bersch (2000) compararam diversos tipos de bebedouros (pendular e chupeta em 3 diferentes relações aves/chupeta), de comedouros (7 diferentes tipos de comedouros tubulares) e de dietas (farelada ou peletizada). Os autores realizaram análise estatística em todos os tratamentos e avaliaram economicamente o desempenho dos equipamentos, escolhendo a melhor opção através do menor custo de produção, juntamente com a diferença estatística do equipamento em relação aos outros. Um dado importante é que os resultados, quanto ao melhor equipamento, diferiram dependendo da região que estava em estudo (diferenças climáticas, de manejo, etc.).

A literatura consultada também registra o uso de modelos matemáticos, visando atender objetivos importantes e que são citados a seguir.

Zhang *et al.* (1996), utilizaram dois experimentos com pintos Leghorn e dados de cinco publicações para determinar se uma simples equação geral poderia ser utilizada para prever a relação entre a quantidade de uma enzima adicionada à dieta e o desempenho dos pintos. Os dados foram analisados pelo teste de ANOVA,

para determinar a significância dos efeitos principais. O teste de amplitude múltipla de Duncan e contrastes ortogonais polinomiais foram usados para a comparação múltipla de médias. As médias dos dados foram também submetidos à análises de regressões linear de primeiro grau, quadrática e cúbica. Na maioria destas análises a quantidade de enzima ou sua atividade foi transformada em valor logaritmo. O estudo demonstrou que há uma relação linear entre a quantidade de enzima adicionada à dieta, quando expressada como um valor logaritmo, e o correspondente desempenho dos pintos. Portanto, os autores demonstraram ser possível prever corretamente a resposta de pintos à suplementação de enzima na dieta, usando uma equação relativamente simples. A equação proporcionou um meio simples de estimar a eficácia da enzima e pode ser influenciada por fatores tais como tipo de enzima, processamento da dieta, tipo e variedade de cereal usado no alimento.

Elfadil *et al.* (1996), utilizaram a análise multivariada (além da univariada) para investigar possíveis associações entre celulite e outras categorias de condenações em um frigorífico. Uma das conclusões dos autores foi a de que variáveis significativamente associadas com celulite, na análise multivariada, podem ser consideradas potenciais preditores e que estes podem compartilhar fatores de risco comuns, predispondo os frangos de corte à celulite.

Em 1997, Kirby *et al.* realizaram uma comparação entre modelos obtidos de regressão logística e modelos obtidos de regressão linear para prever a ocorrência de ascite em frangos de corte. Os autores utilizaram na análise estatística, dados binários (saudável ou doente), os quais podem ser problemáticos, já que estes não vão ao encontro de todas as suposições necessárias à análise estatística mais familiar, tal como ANOVA e regressão linear. Dados binários são discretos e não têm erros normalmente distribuídos, o que contraria uma suposição fundamental de modelos lineares. A regressão logística fornece um método mais apropriado de analisar, estatisticamente, conjuntos de dados binários. Naquele estudo, as habilidades das regressões logística e linear para prever susceptibilidade à ascite, em indivíduos com manifestação subclínica, foram avaliadas, usando dados obtidos de frangos submetidos a dois métodos experimentais para predispor à ascite (estresse por frio e o grampeamento cirúrgico de uma artéria pulmonar). A conclusão do trabalho foi que embora a regressão linear prediga frequentemente a incidência de ascite tão bem

quanto a regressão logística faz, a regressão logística é o teste estatístico mais apropriado para ser usado nesse caso.

Graat *et al.* (1998), realizaram estudo para identificar e quantificar fatores de risco para coccidiose, sendo que a população em estudo foi constituída de 4.774 lotes de frangos de corte, mantidos em 177 granjas. Os lotes foram considerados um caso quando, pelo menos uma ave no lote mostrou presença microscópica de oocistos em raspados intestinais em ciclo de multiplicação. Os outros lotes foram definidos como controles. Isto foi procedido para três tipos de *Eimeria* (*Eimeria acervulina*, *Eimeria tenella* e *Eimeria maxima*). A regressão logística foi usada para avaliar 49 variáveis que influenciam a ocorrência de espécies de *Eimeria*. Os autores encontraram um risco maior de coccidiose devido a fatores ambientais e de manejo, os quais aumentam o risco de contaminação ou que estão relacionados com medidas higiênicas, tais como a falta de uso de macacões pelos visitantes, um pátio de difícil limpeza, baixo nível de higiene, funcionários trabalhando em diversas granjas, presença de outros animais e sistemas de alimentação e bebida difíceis de limpar. Também, a presença de outras doenças na granja e espécies de *Eimeria* encontradas no lote anterior aumentaram o risco de coccidiose.

Um grupo de estudos do Centro Nacional de Pesquisas em Suínos e Aves (CNPSA) da Embrapa (Empresa Brasileira de Pesquisa Agropecuária), também vem estudando técnicas estatísticas para explicar fenômenos em avicultura. Freitas *et al.* (1983), estimaram o peso de frangos machos e fêmeas através de modelos matemáticos. Os autores concluíram que os resultados obtidos poderiam ser utilizados pelo criador para visualizar o crescimento corporal com a idade, verificar a proporção relativa do crescimento corporal entre sexos, estimar a conversão alimentar diária, padronizar o crescimento para seleção de novas linhagens e crescimento controle para comparações com outros tratamentos. Fialho (1999), interpretou a curva de crescimento de Gompertz, a qual descreve o crescimento de animais e tecidos, expressando a massa em função da idade do animal. Fialho & Ledur (2000a e 2000b) descreveram modelos matemáticos estatísticos para estimar, com precisão, curvas de produção de ovos, levando em conta a idade das aves. Os autores concluíram que o modelo proposto pode ser utilizado em situações práticas por técnicos, tanto na pesquisa quanto na produção. Eles desenvolveram um

programa de computador, o qual é executado via internet, estando disponível a qualquer um com acesso à mesma. Algumas das aplicações de tal modelo incluem o planejamento da venda de ovos e a substituição de lotes, da comparação de curvas submetidas a diferentes tratamentos e da predição da produção de ovos para seleção de aves.

Ivey (1999), descreveu um programa computacional, baseado em modelos matemáticos estatísticos, que determina toda a operação de alimentação de frangos de corte, fundamentado no número de aves em cada instalação de crescimento, combinado ao desempenho daquela instalação, adequando a entrega de ração para todos proprietários e fornecendo a ração correta para as aves. Similares a este, hoje em dia existem programas para frangos de corte que usam os valores nutricionais e o custo dos ingredientes juntamente com o lucro esperado e os convertem em formulações de ração que minimizam os custos em alimentação. Um outro exemplo é o programa computacional descrito por Robey *et al.* (2000), o qual, segundo eles, permite alcançar a melhor conversão alimentar, de acordo com os objetivos de mercado quanto ao peso vivo, a idade ao abate e o rendimento que, na totalidade, maximizam o retorno econômico. Os autores também afirmaram que variáveis como tipo de galpão, programa de ventilação, tipo de bebedouro ou outro componente chave em um manejo de granjas, podem ser associadas aos dados de crescimento, sendo analisadas para determinar seus efeitos na variação geral e tendo a sua importância econômica definida.

Sabendo que a resposta imunológica após vacinação é um fator difícil de ser interpretado por veterinários, Soares (1995), bem como Salle *et al.* (1998a, 1998d e 1999c) investigaram um modelo matemático simplificado, usando idade e título de anticorpos, para avaliar a resposta imunológica em reprodutoras de perus. As aves foram divididas em 11 grupos de diferentes idades e 880 amostras de soro foram analisadas para anticorpos contra a doença de Newcastle após vacinação, usando o teste de inibição da hemoaglutinação. Idade e títulos de anticorpos foram tabulados em um diagrama de dispersão. Uma alta correlação foi encontrada entre a idade e a resposta imunológica esperada para cada grupo de animais ($p < 0,05$). Os autores concluíram que podem ser criados modelos matemáticos para cada granja, oferecendo assim, uma interpretação objetiva dos resultados sorológicos da resposta

imune, provocada pela vacina contra o vírus da doença de Newcastle em reprodutoras de perus.

Salle *et al.* (1998c e 1999b), buscaram modelos matemáticos que pudessem ajustar a curva de anticorpos produzida pela vacinação contra doença de Gumboro, doença de Newcastle e bronquite infecciosa. Os dados foram originários de amostras colhidas de 20 lotes de matrizes pesadas de frangos de corte. Os soros foram submetidos aos teste de inibição da hemoaglutinação (HI) para anticorpos, contra doença de Newcastle e vírus neutralização (VN), contra doença de Gumboro e bronquite infecciosa. Os soros foram coletados de aves com 5 a 65 semanas de idade em intervalos de 5 semanas. As médias geométricas dos títulos foram transformadas em logaritmo na base 10, sendo que a variável independente X era a idade das aves (5 a 65 semanas) e a variável Y era o título de anticorpos contra a vacina específica. Análises de variância, regressão linear e não-linear foram realizadas. Foi concluído que é possível traçar modelos matemáticos que explicam a relação entre níveis de anticorpos após vacinação e a idade das aves.

Salle *et al.* (1998b e 1999a), realizaram análises quantitativas para aflatoxina e ocratoxina em 24 amostras de dieta que foram coletadas da fábrica de rações e granjas avícolas, e em fígado e rins de aves refugio, que haviam sido alimentadas com a dieta analisada. As amostras foram divididas em quatro grupos, tendo como base a época do ano, correspondente a verão, outono, inverno e primavera. A detecção das toxinas foi feita através do uso de um teste de ELISA comercial e os resultados foram estudados por análise de regressão e correlação. Os níveis de aflatoxina e de ocratoxina, juntos ou separadamente, foram comparados aos índices de produção do lote, conversão alimentar, percentagem de mortalidade, ganho de peso, percentagem de condenação e com o índice de produção do produtor. Dos resultados obtidos, foi verificado que é possível correlacionar níveis de aflatoxina e de ocratoxina em alimento e vísceras de frangos de corte com os parâmetros produtivos do lote.

Sobre este tema, Salle & Silva (2000), expuseram a necessidade da geração de critérios objetivos para a interpretação dos resultados das monitorizações, sem os quais o processo decisório e as medidas corretivas associadas à decisão tomada, ficam seriamente comprometidos.

2.4 Utilização de redes neurais artificiais em veterinária

Na literatura mundial, não foi encontrado qualquer registro acerca da utilização das redes neurais artificiais em avicultura, bem como nos demais setores da agropecuária, com os mesmos objetivos da presente tese. No entanto, a literatura registra outras abordagens, descritas a seguir, para suinocultura e avicultura.

Xin (1999), desenvolveu um sistema automatizado de análise de imagens, que fornece conforto térmico para suínos e que faz os ajustes ambientais apropriados para melhorar o bem-estar animal e a eficiência produtiva (na forma de um sensor biológico integrado). Em um primeiro momento, o autor examinou a viabilidade de classificar o conforto térmico de suínos jovens através de análise por rede neural, a partir de suas imagens posturais. Foi incluída uma pesquisa das imagens de comportamento postural como entrada em uma rede neural de retropropagação com três camadas, a qual foi treinada para classificar o estado de conforto térmico correspondente, como sendo frio, confortável ou quente.

Em 1996, Roush e colaboradores estudaram a predição de ascite em frangos de corte, através de redes neurais artificiais, realizando comparação entre resultados de diagnósticos de laboratório e a incidência predita pela rede neural. Segundo os autores, a rede neural identificou corretamente a presença ou ausência de ascite. Esta é uma outra alternativa para analisar dados binários (além da regressão logística proposta posteriormente por Kirby *et al.*, 1997).

Roush *et al.* (1997), tornaram a utilizar a rede neural como uma predição probabilística de ascite em frangos de corte. Uma rede neural probabilística (PNN: "probabilistic neural network") foi treinada para prever ascite, baseada em fatores minimamente invasivos, ou seja, fatores fisiológicos que não necessitam da morte da ave. Uma PNN é uma rede neural artificial supervisionada e com três camadas, que classifica padrões de entrada (exemplo: dados fisiológicos) em categorias específicas de saída (exemplo: ascite ou não ascite). As entradas da PNN foram nível de O₂ no sangue, peso corporal, eletrocardiograma (ECG), hematócrito, onda S e taxa cardíaca das aves. A conclusão foi que o uso dos modelos desenvolvidos pode intensificar o diagnóstico de ascite em frangos de corte. Os resultados podem ser úteis na escolha e

no desenvolvimento de linhagens de frangos de corte que não tenham propensão à ascite.

Roush e Cravener (1997), compararam dois tipos de redes neurais artificiais (retropropagação e rede neural de regressão geral) para predição de níveis de aminoácidos em ingredientes alimentares. Além disso, os autores compararam tais redes neurais frente à técnicas de análise de regressão. As redes neurais artificiais tiveram um melhor desempenho do que a análise de regressão, sendo que naquele caso, a rede neural de regressão geral superou a de retropropagação.

3 MATERIAL E MÉTODO

O estudo foi do tipo observacional analítico e transversal.

Os dados utilizados para a análise matemática foram obtidos dos registros de lotes de reprodutoras pesadas já terminados de uma empresa avícola integradora do sul do Brasil, produtora de frangos de corte de uma mesma linhagem.

Foram feitos gráficos de dispersão de todas as variáveis digitadas, com o objetivo de identificar números destoantes (“outliers”), mostrados nos Anexos 1 e 3, utilizando o programa computacional StatView versão 4.53™ (Abacus Concepts Co.®) para sistema operacional Windows®.

A temperatura e a umidade relativa do ar não foram mensuradas nos galpões. Na análise, foram utilizadas a temperatura e a umidade relativa do ar da região, as quais foram obtidas no 8º Distrito de Meteorologia, do Ministério da Agricultura, do Abastecimento e Reforma Agrária (8º DISME - MAARA).

Nesta tese, a palavra "entrada" é utilizada para identificar as variáveis disponíveis ou escolhidas, que foram utilizadas no cálculo do modelo preditivo (contidas no grupo1 de neurônios da Figura 1). O termo "saída" significa a(s) variável(is) a ser(em) predita(s) (contidas no grupo de neurônios número 5 da Figura 1).

Não foi possível relacionar os períodos de recria e de produção, visto que os lotes de recria não correspondiam aos lotes de produção, contidos nas planilhas em papel, preenchidas pelos funcionários da empresa e fornecidas para o presente estudo.

3.1 Período de recria (1-25 semanas de idade)

Os dados foram referentes ao período compreendido entre 09/11/97 a 10/01/99.

Dos vinte lotes de recria disponíveis para a análise, foram eliminados nove deles antes da digitação, restando onze em condições de serem estudados.

Os dados utilizados corresponderam a 273 linhas de registros semanais (219 utilizadas para o treinamento e 54 para o teste da rede) das seguintes variáveis:

- identificação do lote;
- identificação do galpão;
- idade (1 – 25 semanas);
- estação do ano (1 = Inverno: 21/06 a 20/09; 2 = Outono: 21/03 a 20/06; 3 = Primavera: 21/09 a 20/12; 4 = Verão: 21/12 a 20/03);
- temperatura (°C);
- umidade relativa do ar -URA (%);
- número de fêmeas vivas e mortas;
- percentual de mortalidade das fêmeas;
- percentual de mortalidade acumulada das fêmeas;
- número de fêmeas descartadas;
- quantidade de ração por fêmea/dia;
- período do ano em que nasceram (1 = fora de estação: 16/07 a 14/02; 2 = dentro da estação: 15/02 a 15/07),
- peso das fêmeas;
- uniformidade dos lotes.

3.2 Período de produção (26-66 semanas)

Os dados foram referentes ao período compreendido entre 26/04/98 a 19/12/99.

Dos vinte e dois lotes de produção disponíveis para a análise, foi eliminado um deles, restando vinte e um lotes em condições de serem estudados.

Os vinte e dois lotes correspondiam a 990 linhas de dados, das quais, 301 tiveram que ser eliminadas por inconsistência nos seus registros.

Então, os dados utilizados corresponderam a 689 linhas de registros semanais (552 utilizadas para o treinamento e 137 para o teste da rede) das seguintes variáveis:

- idade (25 – 66 semanas);
- estação do ano (1 = Inverno: 21/06 a 20/09; 2 = Outono: 21/03 a 20/06; 3 = Primavera: 21/09 a 20/12; 4 = Verão: 21/12 a 20/03);
- temperatura (°C);
- umidade relativa do ar -URA (%);
- número de fêmeas no lote;
- número de machos no lote;
- percentual de mortalidade acumulada das fêmeas;
- percentual de mortalidade acumulada dos machos;
- quantidade de ração por fêmea/dia;
- quantidade de ração por macho/dia;
- ovos produzidos durante a semana;
- percentagem de produção na semana;
- ovos incubáveis produzidos durante a semana;
- percentagem de aproveitamento na semana;
- ovos incubados produzidos na semana;
- percentagem de incubabilidade na semana;
- pintos produzidos na semana;
- percentagem de eclosão na semana.

3.3 Análise por redes neurais artificiais

Nos procedimentos para obtenção das redes neurais artificiais, foi utilizada a arquitetura de retropropagação (redes recorrentes supervisionadas com 3 grupos de neurônios ocultos e diferentes funções de ativação). O programa computacional utilizado foi o Neuroshell 2 versão 4.0™ (Ward Systems Group®). O esquema da rede está representado na Figura 1 e as suas características estão listadas abaixo.

A camada de entrada (grupo de neurônios número 1) utilizou uma função de escala linear [-1,1]. O primeiro grupo de neurônios da camada oculta, grupo 2, utilizou função de ativação Gaussiana. O segundo grupo oculto, grupo 3, utilizou função de ativação tangente hiperbólica e o terceiro grupo oculto, grupo 4, utilizou a função de ativação de complemento da Gaussiana. A Camada de saída (grupo 5) utilizou uma função de ativação logística (logística sigmóide). As ligações entre neurônios foram ajustadas para taxa de aprendizagem e momento, em 0,1 e os pesos iniciais entre +0,3 e -0,3.

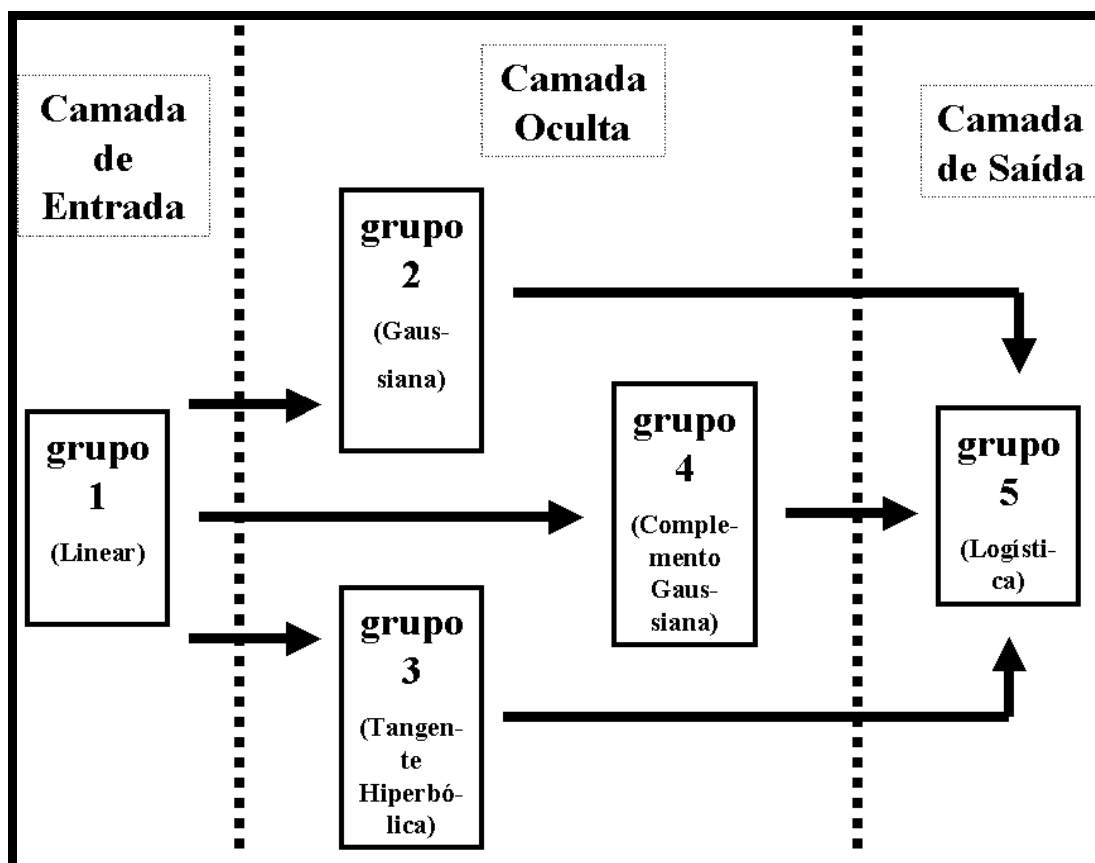


Figura 1 Arquitetura da rede neural artificial de retropropagação utilizada.

Após haverem sido apresentados padrões de entrada à rede neural (Anexos 2 e 4), estes foram propagados através de cada camada, sucessivamente, até que fossem geradas as saídas. Então, elas foram comparadas à saída desejada e um sinal de erro foi calculado para cada uma. Este sinal de erro foi transmitido de volta através da rede (retropropagação). Os pesos das conexões foram, desse modo,

atualizados com o objetivo de se diminuir o erro entre a(s) entrada(s) e a(s) saída(s). Sendo assim, o erro diminuía e a rede neural aprendia o padrão dos dados analisados.

No ponto em que o erro entre o conjunto de aprendizagem e os dados teste foi mínimo, a rede neural de retropropagação foi salva como um arquivo que pode ser acessado através de uma biblioteca de vinculação dinâmica (DLL: "dynamic link library"), a partir de uma planilha do programa Excel versão 97 para Windows 98® (ou outras versões).

Não será demasiadamente aprofundada a descrição do método de obtenção das redes neurais artificiais utilizadas. No entanto, os princípios da técnica de redes neurais artificiais são amplamente discutidos por Kovács (1996) e, especificamente, sobre as redes de retropropagação utilizadas nessa tese, por Rumelhart *et al.* (1986), em seu artigo denominado "Representações de aprendizado por erros de retropropagação". Também não será discutida a comparação de redes de retropropagação com redes probabilísticas (Specht & Shapiro, 1991) ou da comparação de redes de retropropagação com redes neurais de regressão geral - GRNN (Roush & Cravener, 1997), visto não estarem contemplados nos objetivos desta tese.

Os modelos de redes neurais artificiais das variáveis preditas (saídas), foram comparados e selecionados como melhores, baseados no coeficiente de determinação múltipla (R^2), no Quadrado Médio do Erro (QME), bem como pela análise de gráficos, plotando a predição da rede *versus* a predição menos o real. A fórmula utilizada para calcular o R^2 foi $R^2 = 1 - (SSE/SSy)$, onde $SSE = \sum (\text{valor real} - \text{valor predito})^2$ e $SSy = \sum (\text{valor real} - \text{média dos valores})^2$. O QME foi calculado como sendo a média dos valores reais menos os valores preditos, elevados à potência 2 [$QME = \text{média} (\text{valores reais} - \text{preditos})^2$].

É importante que seja entendido que os modelos gerados só tem utilidade para a empresa onde foi realizado o estudo.

A presente tese objetivou aplicar a metodologia das redes neurais artificiais, para serem usadas na estimação dos parâmetros de produção de galinhas reprodutoras pesadas.

4 RESULTADOS E DISCUSSÃO

Conforme pode ser visualizado nos gráficos contidos nos Anexos 1 e 3 (antes e após a eliminação de "outliers"), em muitos casos, foi de suma importância a eliminação de registros sem confiabilidade, caso contrário a rede neural artificial iria "aprender" errado o comportamento dos fenômenos na fase de treinamento.

Para que seja entendido o funcionamento e a utilidade do método, serão mostrados apenas exemplos de uso mais comuns, utilizando as redes neurais artificiais, construídas a partir dos bancos de dados descritos, no capítulo Material e Método.

Todas as previsões e padrões das empresas, ao serem calculadas pelas redes neurais artificiais, permitem visualizar o percentual de contribuição das entradas nessas previsões e padrões. Todas as contribuições (ou influências) de cada variável, em um valor predito, estão descritas nos Anexos 2 e 4.

O tipo de rede utilizada está descrito no capítulo Material e Método, sendo que outros dados, como coeficientes de determinação múltipla (R^2), QME e configurações da rede, podem ser vistos nos Anexos 2 e 4.

4.1 Anotação dos dados na granja

Várias incorreções foram identificadas, quando da digitação no computador, dos dados provenientes das planilhas em papel preenchidas pela empresa. Conforme descrito no capítulo Material e Método, alguns deles tiveram que ser eliminados.

São listados abaixo os erros gerais, comuns às fases de recria e de produção:

- as informações referentes a tratamentos medicamentosos não puderam ser utilizadas, devido à falta de clareza da anotação.

- a anotação da formulação da ração fornecida às aves estava muito confusa, não possibilitando relacioná-la com os lotes que a consumiram.

- não havia anotação do número de machos existentes nos galpões, bem como o peso destes e o número de mortos e descartados. Também não era anotada a quantidade de ração consumida por eles.

- dados como o consumo de alimento acumulado, muitas vezes estavam errados na planilha da empresa, visto que os cálculos foram realizados manualmente.

Erros específicos do período de recria:

- na chegada dos pintos nos galpões, as aves descartadas nesta primeira semana não foram computadas. Tal fato foi levado em conta no momento da digitação, o que alterou outras variáveis, como o número de fêmeas existentes nas semanas seguintes, quantidade de ração por fêmea, etc.

- ao finalizar um lote, as aves sobreviventes eram consideradas como mortas pelos responsáveis pela anotação do dado, com o objetivo de fechar lotes, no sentido contábil da palavra. No momento da digitação, os dados dali em diante foram desconsiderados.

- quando da adição de aves de outros galpões, contabilmente, foi subtraído este número de aves introduzidas no lote do número de aves mortas, ao invés de somá-lo ao número de aves existentes (o último procedimento foi realizado no momento da digitação). Conseqüentemente, outros dados estavam calculados errado, como por exemplo, quantidade de ração por fêmea. Quando possível, foram feitos os ajustes necessários, para aproveitar tais dados na análise matemática.

- na coluna onde deveria haver o número percentual de mortalidade acumulada, estava anotado o número absoluto da mortalidade acumulada.

Se, por um lado, foram lastimáveis estas perdas e erros, por outro, deixaram a evidência de que os responsáveis pela análise dos dados não voltaram à própria história na busca de orientações para futuras decisões.

4.2 Período de recria (1-25 semanas de idade)

Com os dados dos lotes de recria disponíveis, foi possível descrever e testar 37 modelos para mortalidade, quantidade de ração a ser fornecida, peso das aves na semana atual e peso das aves na semana seguinte, como está expresso na Tabela 1.

Tabela 1 Saídas (variáveis a serem preditas), número de modelos (redes) gerados para o período de recria e o QME e o R^2 dos modelos escolhidos.

Saída (variável a ser predita)	Número de modelos	QME	R^2
Mortalidade	4	0,200	93,02
Quantidade de ração	10	66,884	90,01
Peso das aves na semana atual	7	3.714,418	99,12
Peso das aves na semana seguinte	16	2.616,969	99,12

Como exemplo de todo o procedimento empregado na fase de recria, na Tabela 2 está apresentado o resultado dos 16 modelos construídos para a saída “Peso das aves na semana seguinte”. O modelo escolhido foi o calculado pela rede 15, que tem o menor QME e o maior R^2 , além de o mesmo ter apresentado distribuição uniforme na imagem gráfica dos dados, ao plotar a predição da rede *versus* a predição menos o real (Figura 2). A rede 15 teve como variáveis de entrada: a idade, a temperatura, a URA, a mortalidade acumulada, a ração fornecida, o período do ano em que nasceram e a uniformidade.

Tabela 2 Informações das redes neurais artificiais construídas para a saída “peso das aves na semana seguinte”.

Redes	Nent	Noc	Épocas	QME	R ²
01	1	5	1.018	6.666,874	98,38
02	2	5	327	7.352,020	98,21
03	2	5	913	4.041,091	99,02
04	2	5	1.696	6.426,282	98,19
05	3	6	1.619	5.256,596	98,72
06	1	5	888	4.722,976	99,40
07	2	5	1.345	5.652,578	98,62
08	3	6	944	3.965,684	99,04
09	2	5	605	4.395,800	98,88
10	4	6	557	4.778,152	98,84
11	5	6	563	4.673,030	98,86
12	4	6	491	3.821,425	99,02
13	5	6	604	3.626,571	99,07
14	7	6	984	3.145,490	98,96
15	7	6	635	2.616,969	99,12
16	8	6	384	3.327,060	98,88

Legenda: **Nent** – Número de neurônios da camada de entrada; **Noc** - Número de neurônios em cada grupo de neurônios da camada oculta; **Iterações** - Completa passagem através da rede em todo conjunto de padrões de treinamento; **QME** – Quadrado Médio do Erro; **R²** - Coeficiente de Determinação Múltipla.

Infelizmente, não existiam registros das temperaturas e das URA no interior dos galpões, o que demonstra que esses dados não são considerados na análise histórica dos lotes por parte da empresa. Sob essas circunstâncias, e com a intenção de demonstrar que é possível caracterizar a contribuição das variáveis de entrada sobre a saída eleita, restou buscar os registros das temperaturas e das URA no meio externo aos galpões. Acredita-se que esses valores tenham alguma relação com o que ocorre no interior dos galpões. Tzschentke *et al.* (1996), demonstraram através de análises de regressão linear e múltipla, que há relação entre a temperatura ambiental, a umidade relativa do ar e a velocidade dos ventos com o balanço térmico dos animais. Naquele trabalho, os autores afirmaram que as condições climáticas no interior dos galpões podem ser modificadas, visando melhor conforto térmico das aves e que esse bem-estar se traduziria em melhoria do desempenho produtivo dos animais. Assim sendo, o manejo das cortinas, a colocação de ventiladores, de aspersores, de aquecedores, entre outras medidas, tem efeito benéfico sobre os

animais. Deve ser ressaltado que essas providências são usadas rotineiramente pela empresa com esse objetivo. Porém, não houve a preocupação de quantificar o benefício alcançado. Isso poderia ter sido feito, anotando as temperaturas e as URA internas, comparando-as com as do meio ambiente externo e medindo o reflexo sobre o parâmetro de produção desejado.




Figura 2 Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída “peso das aves na semana seguinte”.

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 na variável a ser predita. Com este valor à disposição, o profissional avícola pode avaliar e propor as correções pertinentes, quando possíveis e necessárias. É uma ferramenta de importância muito grande para o gerenciamento do processo, neste caso, da fase de recria. Algumas entradas podem ser modificadas. Já outras, como idade e mortalidade acumulada, são imutáveis. Porém, é possível alterar a temperatura ambiente, a umidade relativa do ar no interior dos aviários e a quantidade de ração com o intuito de melhorar o peso das aves na semana seguinte.

Destas alterações, algumas são mais fáceis de serem realizadas do que outras. Em qualquer circunstância, as medidas tomadas para melhorar o processo poderão ter sua eficácia medida ao ser gerado o novo modelo que conterà as modificações efetuadas.

Na Figura 3, são apresentadas as contribuições das entradas que compuseram o modelo para a saída “peso das aves na semana seguinte”. É possível perceber que, como era de se esperar de aves em recria, a idade tem a maior contribuição sobre o peso das aves na semana seguinte (34,04%). Por outro lado, fica demonstrado qual a participação da temperatura ambiente (14,33%), da umidade relativa do ar (9,67%), da mortalidade acumulada (8,48%), da ração fornecida aos animais (10,70%), do período (10,88%) e da uniformidade dos animais (11,95%) para a saída em estudo.

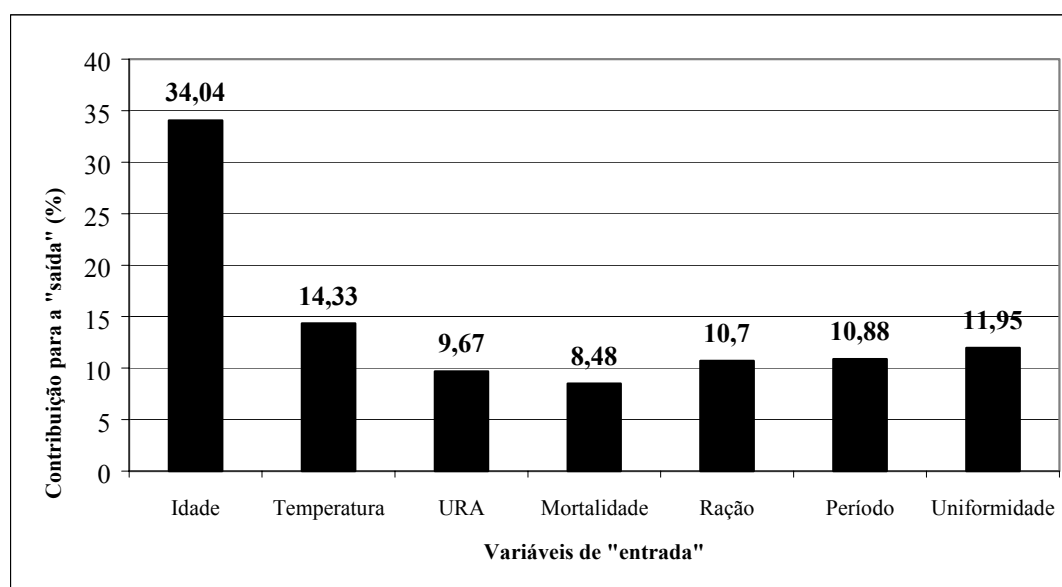


Figura 3 Contribuições das diferentes entradas na saída “peso das aves na semana seguinte”.

A Figura 4 mostra as contribuições da idade, da estação do ano, da temperatura ambiente e da umidade relativa do ar sobre a mortalidade acumulada das fêmeas. Os dados demonstram que a temperatura ambiente tem praticamente a mesma participação do que a idade, sobre a mortalidade acumulada das reprodutoras durante a fase de recria. A estação do ano tem participação intermediária e a menor contribuição é dada pela umidade relativa do ar. Como não é possível alterar a idade dos animais, nem a estação do ano, resta a alternativa de proporcionar-lhes o melhor

conforto térmico para minorar a mortalidade. No modelo gerado, a mortalidade acumulada das fêmeas é influenciada em 44,27% pelas variáveis passíveis de interferência humana.

Contribuições de outras variáveis podem ser encontradas no Anexo 2.

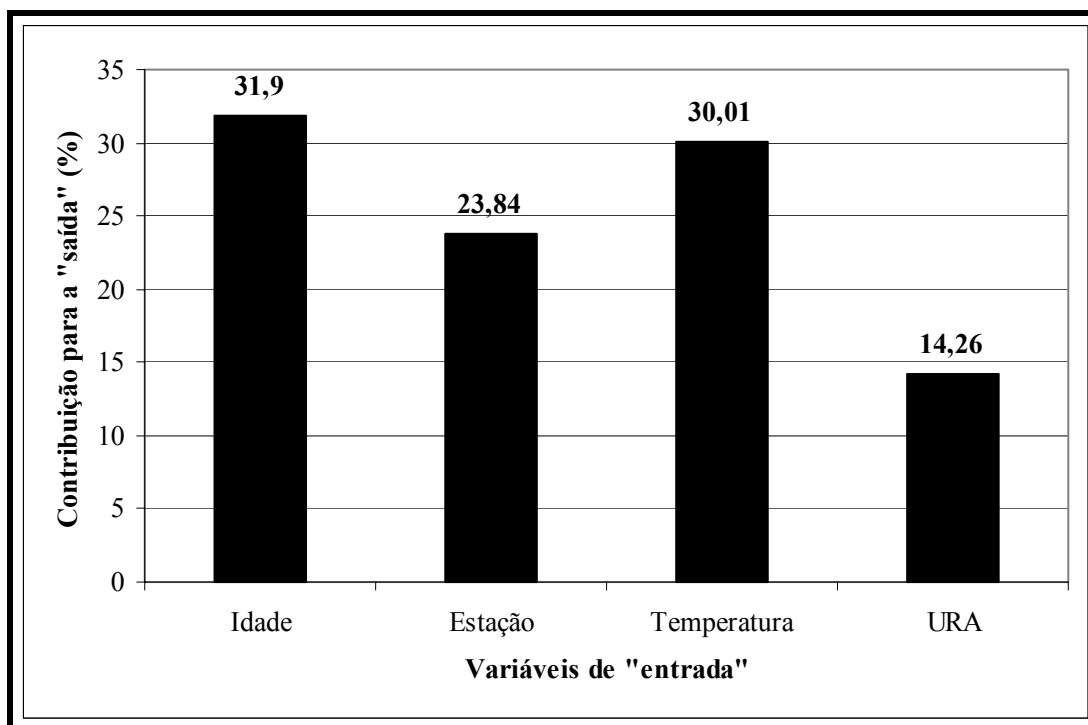


Figura 4 Contribuições das diferentes entradas na saída “mortalidade acumulada das fêmeas”.

O resultado final da rede neural artificial pode ser expresso numa planilha do programa Excel versão 97 para Windows 98®, ou em versões anteriores, mostrada na Figura 5. Nela, é possível fazer simulações a partir dos modelos de redes neurais artificiais anteriormente calculados e contidos na planilha.

Exemplo de uso da planilha da Figura 5. Suponha-se que o usuário da planilha realizou o fechamento semanal do lote, quando as aves possuíam 15 semanas de idade. Assim sendo, anota o número 15 na linha “Idade (semanas)”, digita o número da estação do ano (1 a 4) na linha “Estação do ano”. Aqui cabe um esclarecimento: é necessário informar este dado, embora “Estação do ano” não faça parte do modelo de predição “Peso das aves na semana seguinte”. A estação do ano participa do modelo “Mortalidade acumulada” e, esse último, é necessário aos

cálculos simulatórios do peso futuro que se quer predizer. Continuando, repete a digitação com os valores correspondentes a cada uma das linhas chegando, finalmente, à "Uniformidade do lote". Todos os valores digitados até aqui não podem ser modificados, pois são a história do lote em questão. Por outro lado, a "Quantidade de ração" a ser oferecida poderá ser modificada simulando o que acontecerá com o peso dos animais na semana seguinte (semana 16). Desta forma, o usuário digitará a quantidade de ração que pretende oferecer aos animais na linha correspondente a este campo. Automaticamente é iniciada a simulação da quantidade de gramas de alimento que ele necessitará fornecer por ave, na semana 15, para que o lote atinja o peso esperado na semana 16.

A planilha é dinâmica, ou seja, à medida que os valores de entrada são modificados (Idade, Estação do ano, Temperatura, URA, Mortalidade, Período, Uniformidade e Quantidade de ração a ser fornecida), a saída é automaticamente modificada (peso que a ave terá na semana seguinte: linha "Peso na próxima semana"). Já o peso que a ave deveria ter na próxima semana (linha "Peso que deveria ter com": 1.845,83 gramas) é um valor que obedece a um padrão de peso, o qual também foi calculado pela rede neural artificial (a partir da Idade e Período). A linha que expressa a diferença entre o resultado da simulação e o padrão da empresa servirá de orientação na digitação de um valor maior ou menor durante o processo simulatório. No presente exemplo, se forem dadas 73,5 gramas de ração, o peso esperado para a próxima semana será de 1.846,39 gramas e estará 0,56 gramas acima do modelo da empresa para a 16^a semana. Se for digitado 72 gramas, o peso esperado será de 1.840,72 gramas e estará 5,12 gramas abaixo do padrão da empresa. Por outro lado, se forem oferecidas 75 gramas, o peso será de 1.852,14 gramas e ficará acima do padrão em 6,31 gramas. Assim sendo, a quantidade de alimento a ser oferecida a estes animais na 15^a semana deverá ser de 73,5 gramas, pois essa quantidade levará ao peso mais próximo daquele predito no modelo para a semana seguinte.

	A	B	C	D	E	N
2		Entradas	Fêmeas	Padrão		
3		<i>Idade (semanas)</i>	15			
4		<i>Estação do ano</i>	4			1 (21/06-20/09); 2 (21/03-20/06); 3 (21/09-20/12); 4 (21/12-20/03).
5		<i>Temperatura</i>	19,7			Obs.: Digitar os dados do lote na semana atual nas células em itálico. Simular a quantidade de ração na célula com contorno.
6		<i>URA</i>	76			
7		<i>Mortalidade</i>	4,35	4,26	%	
8		<i>Período</i>	1			
9		<i>Uniformidade do lote</i>	65			1 – 16/07 a 14/02: fora de estação; 2 – 15/02 a 15/07: estação
10		Quantidade de ração a ser fornecida	73,50	78	gr.	
11						
12						
13		Peso na próxima semana				
14		1.846,39	Gramas			Dif. simulação - padrão
15						0,56
16		Peso que deveria ter com				Gramas
17		16	Semanas			
18		1.845,83	Gramas			

Figura 5 Planilha eletrônica para a simulação do arraçoamento dos animais e seu reflexo no peso da semana seguinte.

Desta forma, ao dispor dos modelos calculados por redes neurais artificiais e ao colocá-los numa planilha eletrônica, o usuário da planilha poderá simular a quantidade de ração necessária por ave, para que a diferença entre o padrão de peso da empresa e o peso real que estas aves irão alcançar seja o menor possível, a fim de que o desempenho das aves não seja prejudicado pelo excesso ou diminuição do peso corporal.

4.3 Período de produção (26-66 semanas)

Com os dados dos lotes de produção disponíveis, foi possível descrever e testar 248 modelos para 16 variáveis, como está expresso na Tabela 3.

Tabela 3 Saídas (variáveis a serem preditas), número de modelos (redes) gerados para o período de produção e o QME e o R^2 dos modelos escolhidos.

Saída (variável a ser predita)	Número de modelos	QME	R^2
Percentual de mortalidade acumulada das fêmeas	06	0,499	92,42
Percentual de mortalidade acumulada dos machos	06	36,143	84,75
Quantidade de ração por fêmea/dia na semana atual	07	5,264	83,65
Quantidade de ração por macho/dia na semana atual	07	71,934	88,81
Ovos produzidos durante a semana atual	10	2.081.968,802	92,93
Ovos a serem produzidos na semana seguinte	15	377.954,975	98,55
Percentagem de produção na semana atual	15	1,470	98,80
Ovos incubáveis produzidos durante a semana atual	15	164.901,669	99,40
Ovos incubáveis a serem produzidos na semana seguinte	17	450.217,883	98,06
Percentagem de aproveitamento na semana atual	17	0,941	89,20
Ovos incubados produzidos durante a semana atual	17	10.747.105,456	76,30
Ovos incubados a serem produzidos na semana seguinte	22	11.247.903,636	69,78
Percentagem de incubabilidade na semana atual	22	17,933	93,57
Pintos produzidos durante a semana atual	22	350.482,534	99,07
Pintos a serem produzidos na semana seguinte	25	8.568.400,021	73,19
Percentagem de eclosão na semana atual	25	3,518	88,74

Como exemplo de todo o procedimento empregado no período de produção, na Tabela 4 é apresentado o resultado da construção dos 15 modelos construídos para a saída “Ovos a serem produzidos na semana seguinte”. O modelo escolhido foi o calculado pela rede 15, por ter o menor QME e o maior R^2 , além de o mesmo ter apresentado distribuição uniforme na imagem gráfica dos dados, ao plotar a predição da rede *versus* a predição menos o real (resíduo).

Tabela 4 Informações das redes neurais artificiais construídas para a saída “ovos produzidos na semana seguinte”.

Modelos	Nent	Noc	Nsa	Épocas	QME	R²
01	1	11	16	136	6.461.762,513	75,13
02	2	11	16	165	5.340.537,943	79,45
03	3	11	16	104	6.266.087,446	75,88
04	6	9	13	112	1.264.896,283	95,13
05	4	10	12	130	1.453.383,485	94,41
06	5	11	12	107	1.478.954,604	94,31
07	6	11	12	182	1.262.520,287	95,14
08	8	11	12	167	1.037.144,494	96,01
09	10	11	12	150	712.064,196	97,26
10	5	11	12	107	1.196.222,567	95,40
11	11	11	11	75	506.702,564	98,05
12	2	10	11	163	582.490,724	97,76
13	5	10	11	258	457.969,438	98,24
14	4	10	11	111	611.518,886	97,65
15	8	11	11	258	406.542,258	98,25

Legenda: **Nent** – Número de neurônios da camada de entrada; **Noc** - Número de neurônios em cada grupo de neurônios da camada oculta; **Nsa** - Número de neurônios da camada de saída; **Iterações** - Completa passagem através da rede em todo conjunto de padrões de treinamento; **QME** – Quadrado Médio do Erro; **R²** - Coeficiente de Determinação Múltipla.

Na Figura 6 é apresentada a contribuição ou a participação de cada uma das entradas sobre a saída escolhida. Como já foi comentado no subcaptítulo sobre recria, algumas entradas podem ser modificadas, e outras, como estação do ano, idade e mortalidade acumulada são imutáveis. Porém, é possível alterar a temperatura e a URA no interior dos galpões e a quantidade de ração com o intuito de melhorar o número de ovos a serem produzidos na semana seguinte. Na Figura 6 são apresentadas as contribuições das entradas que compuseram o modelo para a saída “ovos a serem produzidos na semana seguinte”. É possível perceber que, como era de se esperar em aves de produção, a quantidade de ovos produzidos na semana atual tem a maior contribuição sobre a produção de ovos na semana seguinte (28,35%). Por outro lado, fica demonstrado qual a participação da idade (16,06%), do número de fêmeas no lote (11,74%), da ração fornecida às fêmeas (11,05%), da temperatura ambiente (9,25%), da umidade relativa do ar (8,77%), da estação do ano (7,45%) e da mortalidade acumulada das fêmeas (7,33%).




Figura 6 Contribuições das diferentes entradas na saída “ovos a serem produzidos na semana seguinte”.

A Figura 7 mostra as contribuições da idade, estação do ano, temperatura ambiental, umidade relativa do ar e do número de fêmeas sobre a mortalidade acumulada das fêmeas. Os dados demonstram que a temperatura ambiental e a URA juntas têm praticamente a mesma participação do que a estação do ano sobre a mortalidade acumulada das reprodutoras durante a fase de produção. A idade e o número de fêmeas do lote têm a maior participação. Como já foi dito, não é possível alterar a idade dos animais, nem a estação do ano e o número de fêmeas. Assim sendo, novamente é apontada a alternativa de proporcionar o melhor conforto térmico para minorar a mortalidade. No modelo gerado, a mortalidade acumulada das fêmeas é influenciada em 19,43% pelas variáveis passíveis de interferência humana, pelo menos, em parte.




Figura 7 Contribuições das diferentes entradas na saída “mortalidade acumulada das fêmeas”.

Como foi verificado nas Figuras 6 e 7, os modelos apresentam as contribuições das entradas em relação à saída desejada. Em ambas as figuras, existem situações imutáveis, porém para aquelas passíveis de modificações, as medidas de correção poderão ser priorizadas de acordo com a contribuição, sendo que a eficácia das ações corretivas poderá ser medida no modelo seguinte a ser construído.

O resultado final da rede neural artificial está expresso em planilhas eletrônicas, mostradas nas Figuras 8, 9 e 10. Nelas, é possível fazer simulações a partir dos modelos de redes neurais artificiais, anteriormente calculados e contidos na planilha.

O mesmo procedimento utilizado para simular o ganho de peso no período de recria, pôde também ser empregado para a produção de ovos.

Exemplo de uso das planilhas das Figuras 8, 9 e 10: suponha que o usuário da planilha realizou o fechamento semanal do lote, quando as aves possuíam 40 semanas de idade. Assim sendo, na planilha correspondente à Figura 8, ele anota o número 40 na linha “Idade das aves”, digita o número da estação do ano (1 a 4) na linha “Estação do ano”. Continuando, repete a digitação com os valores correspondentes a cada uma das linhas chegando, finalmente, à "Ovos produzidos na

semana". Todos os valores digitados até aqui não podem ser modificados, pois são a história do lote em questão.

	A	B	C	D
1	Entradas	Real	Padrão	
2	Idade das aves	<i>40</i>		
3	Estação do ano	<i>1</i>		1 - Inverno (21/06-20/09);
4	Temperatura	<i>14,1</i>		2 - Outono (21/03-20/06);
5	URA	<i>84</i>		3 - Primavera (21/09-20/12);
6	Número de fêmeas no lote	<i>5.711</i>		4 - Verão (21/12-20/03).
7	Número de machos no lote	<i>580</i>		
8	Mortalidade das fêmeas acumulada	<i>3,05</i>	2,36	
9	Mortalidade dos machos acumulada	<i>7,93</i>	11,63	Obs.: Digitar os dados do lote na semana
10	Ovos produzidos na semana	<i>29.180</i>	28.045,13	atual somente nas células em itálico.
11	Porcentagem de produção	72,99	70,15	Não alterar números em negrito

Figura 8 Planilha eletrônica para verificar o desempenho do lote.

Na planilha da Figura 9, a "Quantidade de ração" a ser oferecida às fêmeas poderá ser modificada, simulando o que acontecerá com a produção de ovos na semana seguinte (semana 41). Desta forma, o usuário digitará a quantidade de ração que pretende oferecer às fêmeas na linha correspondente a este campo. Automaticamente é iniciada a simulação da quantidade de gramas de alimento que ele necessitará fornecer por fêmea, na semana 40, para que o lote atinja a produção de ovos esperada na semana 41.

	A	B	C	D	E	F	G	H
1	Semana 40					Simulação		Padrão
2	Quantidade de Ração a ser fornecida aos machos							165 gr.
3	Quantidade de Ração a ser fornecida às fêmeas							174 gr.
4								
5	Parâmetros de Produção observados na semana					41	(próxima)	
6		Predição	%	Padrão	%	Diferença	%	
7	Produção de ovos	28.545	71,40	28.045	70,15	500	1,25	

Figura 9 Planilha eletrônica para a simulação da produção de ovos na semana seguinte a partir da quantidade de ração fornecida às aves na semana atual.

À medida que são modificados os valores de entrada (idade, estação do ano, temperatura, URA, número de aves, mortalidade, ovos produzidos, e quantidade de ração a ser fornecida), a saída é automaticamente modificada (quantidade de ovos produzidos: linha “Produção de ovos”). Já a produção de ovos que o lote deveria ter na semana seguinte (coluna “Padrão”: 28.045 ovos) é um valor que obedece a um padrão de produção, o qual também foi calculado pela rede neural artificial (a partir da idade, estação do ano, temperatura, URA, número de fêmeas e mortalidade). A coluna que expressa a diferença entre o resultado da simulação e o padrão da empresa servirá de orientação na digitação de uma quantidade maior ou menor de ração durante o processo simulatório. No presente exemplo, se forem dadas 174 gramas de ração às fêmeas, a produção de ovos na semana seguinte será de 28.545 ovos e estará 1,25% acima do modelo da empresa para a 41ª semana. Como guia, a planilha calcula também a quantidade de ração a ser fornecida, na coluna “Padrão”: 171gr. (modelo dependente da idade, estação do ano, temperatura, URA, número de fêmeas e mortalidade).

Desta forma, ao dispor dos modelos calculados por redes neurais artificiais e colocá-los numa planilha eletrônica, o usuário da planilha pode simular a quantidade de ração necessária por ave, para que a diferença entre o padrão de ovos produzido

pela empresa e os ovos que realmente estas aves irão produzir seja a menor possível, a fim de que o desempenho das aves não seja prejudicado pelo excesso ou diminuição da quantidade de ração fornecida.

Em uma outra planilha (Figura 10), é possível simular a quantidade de pintos eclodidos a partir dos ovos realmente incubados provenientes deste lote. Basta digitar o número de ovos que serão incubados (linha “Quantidade de ovos a serem incubados”: 27.520) e a planilha calcula a quantidade de pintos que irão eclodir (linha “Produção de pintos”: 22.709) a partir de um modelo dependente de: idade, estação do ano, temperatura, URA, número de aves, mortalidade, ração fornecida e ovos incubados.

	A	B	C	D	E	F	G
1	Semana 40		Simulação				
2	Quantidade de ovos a serem incubados		27.520				
3							
4		Predição %	Padrão %	Diferença %			
5	Produção de pintos	22.709	82,52	24.258	88,15	-1.549	-5,63
6							

Figura 10 Planilha eletrônica para a simulação da quantidade de pintos produzidos a partir de certa quantidade de ovos incubados.

Os exemplos anteriores serviram como demonstrativos da maleabilidade e da aplicabilidade do método. Na verdade, e como já foi dito, o procedimento é dinâmico e as escolhas das entradas e saídas dependem da competência e da imaginação do usuário, as quais, essa metodologia não pretende substituir.

Considerando que o delineamento foi do tipo transversal, os modelos servem apenas para avaliar o uso da técnica. O próximo passo do estudo deverá ser um estudo prospectivo a campo, o qual buscará a validação de modelos.

4.4 Gerenciamento avícola - incursão ao futuro

Num mundo em que toda a produção é comandada por números, simulações econômicas e em que uma decisão envolve milhões ou até bilhões de reais, é inadmissível que certas decisões em avicultura sejam tomadas levando em conta somente experiências pré-concebidas e sensações "epidérmicas" do corpo técnico, quando se dispõe da informática e de técnicas matemáticas para a tomada de decisão com critérios científicos.

Peso das aves, produção de ovos, mortalidade e registros de consumo de alimentos deveriam ser analisados diariamente com o uso de sistemas de computador dentro dos galpões. Os registros ficariam disponíveis dentro de minutos e os gerentes poderiam tomar decisões a respeito das ações para o dia seguinte. Em muitos casos, o desempenho do lote, medidas ambientais, dados do processamento de ovos e formulações das rações poderiam estar todos integrados em uma rede de análise. Alguns sistemas sofisticados podem relacionar dois ou mais parâmetros e até sugerir possíveis causas para vários problemas.

Os computadores permitem comparações imediatas com lotes anteriores. Históricos dos lotes são facilmente preparados e os registros podem ser tão detalhados quanto for desejado. Deve ser ressaltado que os computadores são excelentes ferramentas para agilizar a análise de registros, mas eles não substituem a necessidade de observação diária das aves por técnicos treinados.

O método proposto na presente tese visa, se não a eliminação, a diminuição do erro quando o técnico toma uma decisão sobre os procedimentos que envolvem o processo produtivo avícola. Na forma proposta, estarão à disposição do profissional critérios objetivos, fundamentados cientificamente e simulações de acontecimentos, caso ele tome esta ou aquela decisão, bem como o estudo da influência (contribuição) de cada parâmetro no fenômeno que lhe interessa.

Felizmente, nos últimos anos, foram publicados trabalhos como o de Lima & Bersch (2000), os quais trazem uma característica importante dos novos tempos, ao afirmarem que “mais importante do que somente a avaliação econômica de um

processo, é a análise matemática procedida nos dados, pois esta é a única forma de garantir a repetitibilidade do fenômeno em estudo”.

São poucos os técnicos de campo que se preocupam com a repetitibilidade do fenômeno. A maioria faz simulações ou experimentações no plano real, sem obedecer a metodologia científica e sem realizar análises estatísticas dos seus resultados. Muitas vezes as conclusões obtidas acarretam enormes prejuízos econômicos, porque os resultados não são corretamente analisados e, se isso ocorrer, não será conhecida a probabilidade de que a modificação proposta repita o benefício desejado.

Devem ser construídos modelos matemáticos para avaliar a biossegurança em lotes de matrizes dentro da amplitude de certas situações. As projeções devem incorporar tamanho e tipo de sistema de produção, natureza da doença, e risco de infecção. Estudos de simulação geralmente demonstram que o retorno de um investimento em biossegurança aumenta em relação à severidade da doença e ao risco de exposição.

Há muito que a informática é impulsionadora das fantasias humanas. Os exemplos mais conhecidos da viagem da imaginação é o computador HAL que Arthur Clarke immortalizou na película antológica denominada "2001 - Uma odisséia no espaço" e o livro "Eu, Robô", de Isaac Asimov. O homem chegou a 2001 sem viagens interestelares, ou robô semelhante ao de Asimov, mas com computadores que "falam" e "aprendem" à semelhança de HAL. A informática passou a ter enorme importância na vida das pessoas na sociedade moderna. Exemplo disso foi a ameaça do "bug" do milênio sobre quase todos os aspectos dos mundos civil e militar. A visão do futuro foi oferecida há pouco tempo por Kurzweil (1999). O homem que inventou a máquina de leitura para cegos no ano de 1976 e o sintetizador musical em 1984 previu, e acertou, a explosão da internet no mundo atual. Ele fez uma previsão hipotética do que acontecerá no mundo entre os anos 2009 e 2099. Dentre suas divagações, o autor afirma que, no ano 2019, as operações computacionais serão feitas maciçamente por redes neurais paralelas e algoritmos genéticos.

Leitores desavisados podem pensar que a tecnologia de redes neurais artificiais é tão hermética quanto algumas tarefas especializadas e acadêmicas, às quais ela tem sido aplicada e que estas redes raramente desempenham um papel

construtivo e real no dia-a-dia do veterinário. Entretanto, uma proporção cada vez maior de dados de produção e de monitoramento são hoje gerados e tornam-se disponíveis de forma digital. Outros mais serão acrescentados e esse manancial digitalizado estará disponível para formar bancos de dados que serão analisados por programas computacionais cada vez mais modernos.

Acredita-se que no futuro serão registradas as causas de mortalidade e o número de aves doentes nos galpões, anotando-se tanto o diagnóstico clínico quanto o laboratorial. Serão utilizadas várias informações, como temperatura, precipitação pluviométrica, tipos de equipamentos no galpão, formulação da ração, para executar uma modelagem matemática mais aprofundada e que permita a identificação direta das causas de problemas mais importantes. Serão realizados monitoramentos mais adequados, tanto sorológico, microbiológico, quanto de micotoxinas, pois será quantificado o prejuízo das mesmas.

E no final, todos estes dados, aliados a outros dados de recria, produção, incubatório, integração, frigorífico e custo de cada um dos setores, possibilitarão a inter-relação de todas as variáveis e a mensuração de risco das decisões a serem tomadas, almejando sempre a melhor relação custo / benefício. E o mais importante, tudo isto com validade científica e aplicabilidade prática.

O trabalho do veterinário avícola irá continuar e ele terá que garantir que as redes neurais humanas, que compreendem 10^{15} interconexões, um bilhão de vezes mais do que a média de uma rede artificial, continuem a enfrentar os desafios de gerarem novos métodos que impulsionem o desenvolvimento científico e tecnológico do Brasil.

5 CONCLUSÃO

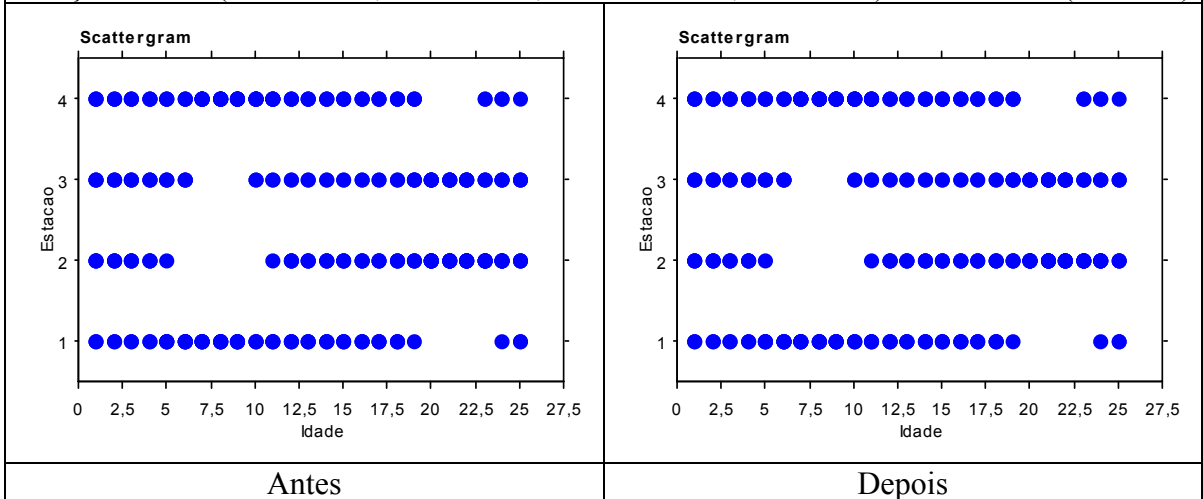
Os resultados obtidos demonstram que é possível explicar os parâmetros de desempenho de reprodutoras pesadas, através da utilização de redes neurais artificiais. Foram gerados modelos de redes neurais artificiais, os quais informam (e em algumas ocasiões simulam e predizem) mortalidade acumulada das fêmeas, quantidade de ração a ser fornecida ao lote diariamente, peso das fêmeas na semana atual, peso das aves na semana seguinte no período de Recria e mortalidade acumulada das fêmeas, mortalidade acumulada dos machos, quantidade de ração a ser fornecida às fêmeas diariamente, quantidade de ração a ser fornecida aos machos diariamente, ovos produzidos durante a semana atual, ovos a serem produzidos na semana seguinte e pintos produzidos na semana atual no período de Produção.

A técnica permite a tomada de decisões criteriosas por parte do corpo técnico para os diferentes lotes em recria e produção, alicerçadas em critérios gerados cientificamente.


Além disso, este método permite simulações das conseqüências de tais decisões e fornece a percentagem de contribuição de cada variável nos fenômenos sob estudo.

ANEXO 1 - Análise gráfica dos dados de recria (antes e depois da eliminação de “outliers”)


Estação do ano (1 – Inverno; 2 – Outono; 3 – Primavera; 4 – Verão) versus Idade (semanas)



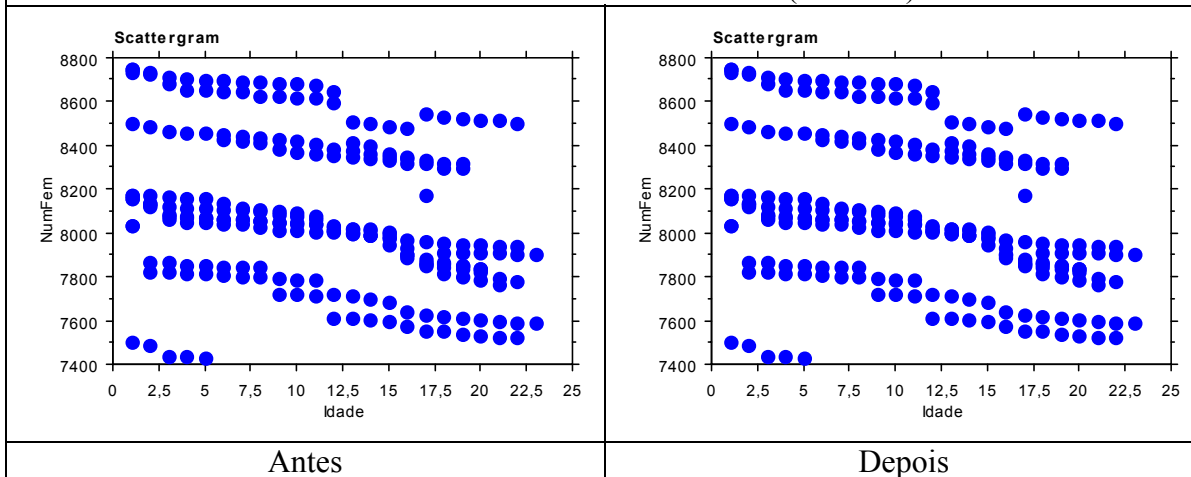
Temperatura (°C) versus Idade (semanas)



Umidade Relativa do Ar (%) versus Idade (semanas)



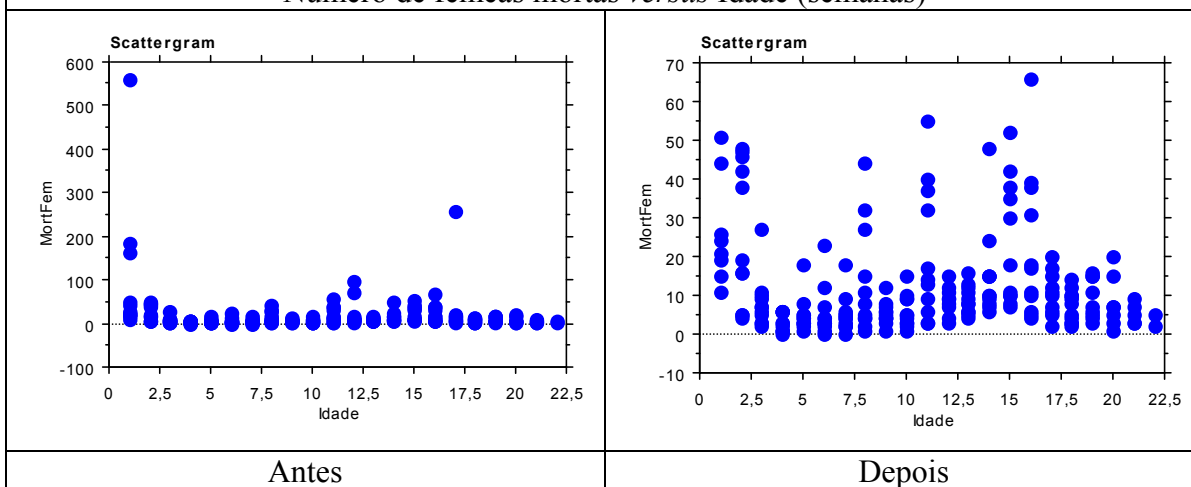
Número de fêmeas vivas *versus* Idade (semanas)



Antes

Depois


Número de fêmeas mortas *versus* Idade (semanas)



Antes

Depois


Percentual semanal de mortalidade das fêmeas *versus* Idade (semanas)




Antes

Depois

Percentual de mortalidade acumulada das fêmeas *versus* Idade (semanas)

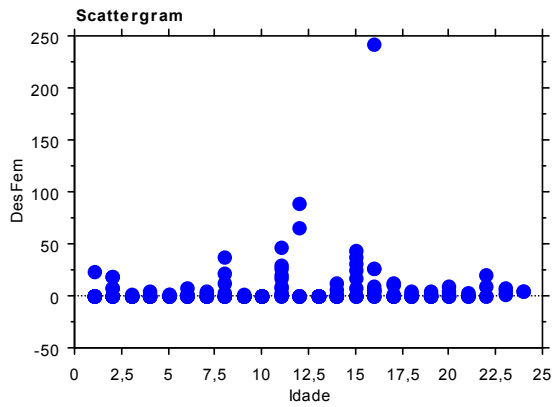


Antes




Depois

Número de fêmeas descartadas *versus* Idade (semanas)

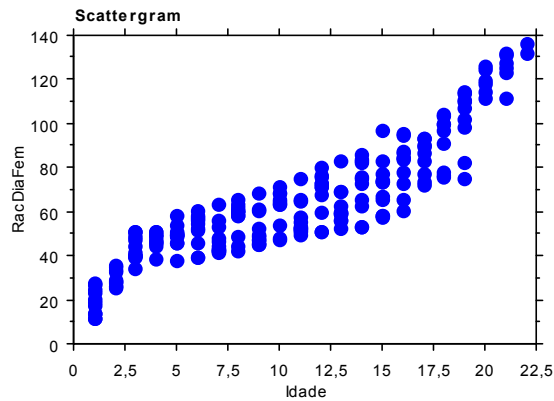


Antes

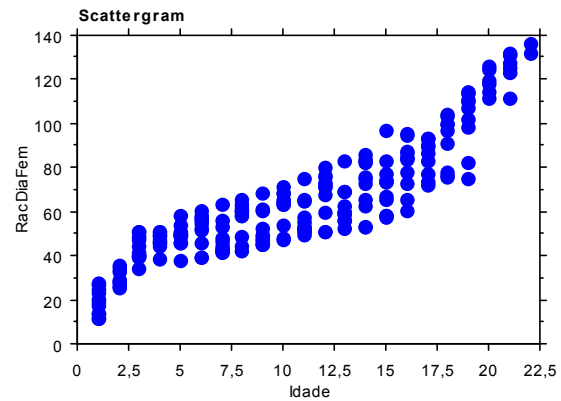


Depois

Quantidade de ração por fêmea / dia (gramas) *versus* Idade (semanas)

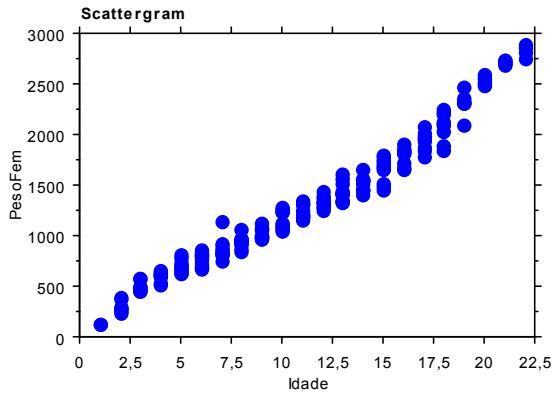


Antes




Depois

Peso das fêmeas (gramas) *versus* Idade (semanas)




Antes




Depois

Peso das aves na semana seguinte (gramas) *versus* Idade (semanas)




Antes

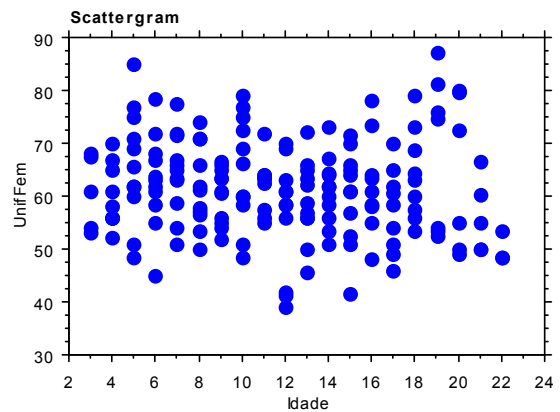


Depois

Uniformidade dos lotes (%) *versus* Idade (semanas)



Antes



Depois

ANEXO 2 - Contribuições, informações e gráficos das redes neurais artificiais geradas para o período de recria

Contribuição de cada entrada na saída: mortalidade acumulada das fêmeas (%)

Modelos	Entradas			
	Idade (sem)	Estação	Temp (°C)	URA (%)
Rede01	100,00	-	-	-
Rede02	48,88	51,12	-	-
Rede03	47,11	24,27	28,62	-
Rede04	31,90	23,84	30,01	14,26

Informações das redes construídas para a saída: mortalidade acumulada das fêmeas (%)

Modelos	Dados				
	Nent	Noc	Épocas	QME	R ²
Rede01	1	5	318	0,735	49,83
Rede02	2	5	482	0,307	79,04
Rede03	3	6	202	0,474	67,65
Rede04	4	6	763	0,200	93,02




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída mortalidade acumulada das fêmeas (%).

Contribuição de cada entrada na saída: quantidade de ração fornecida ao lote (gramas)

Modelos	Entradas					
	Idade (sem)	Estação	Temp (°C)	URA (%)	Mortal (%)	Período
Rede01	100,00	-	-	-	-	-
Rede02	61,97	38,03	-	-	-	-
Rede03	55,96	-	23,72	20,32	-	-
Rede04	42,57	20,09	16,71	20,63	-	-
Rede05	67,01	-	-	-	32,99	-
Rede06	35,66	-	24,64	15,87	23,82	-
Rede07	73,48	-	-	-	-	26,52
Rede08	44,91	-	18,60	18,70	-	17,79
Rede09	28,72	-	19,65	19,21	13,88	18,54
Rede10	29,03	19,50	13,55	8,44	16,28	13,20

Informações das redes construídas para a saída: quantidade de ração fornecida ao lote (gramas)

Modelos	Dados				
	Nent	Noc	Épocas	QME	R ²
Rede01	1	5	545	88,888	86,73
Rede02	2	5	221	102,548	84,69
Rede03	3	6	243	71,754	89,28
Rede04	4	6	137	113,883	82,99
Rede05	2	5	845	70,203	88,14
Rede06	4	6	180	101,376	82,87
Rede07	2	5	505	66,884	90,01
Rede08	4	6	151	96,648	85,57
Rede09	5	6	180	82,99	85,97
Rede10	6	6	142	95,87	83,80




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída quantidade de ração fornecida ao lote (gramas).

Contribuição de cada entrada na saída: peso das fêmeas na semana atual (gramas)

Redes	Idade (sem)	Estação	Temp (°C)	URA (%)	Período
Rede01	100	-	-	-	-
Rede02	63,25	36,75	-	-	-
Rede03	47,26	-	34,02	18,72	-
Rede04	35,24	32,13	16,97	15,66	-
Rede05	69,74	-	-	-	30,26
Rede06	51,25	22,26	-	-	26,49
Rede07	38,24	20,81	17,24	8,56	15,15

Informações das redes construídas para a saída: peso das fêmeas na semana atual (gramas)

Modelos	Dados				
	Nent	Noc	Épocas	QME	R ²
Rede01	1	5	2.319	6.571,036	98,44
Rede02	2	5	1.246	3.924,757	99,07
Rede03	3	6	1.700	5.441,536	98,71
Rede04	4	6	767	5.143,925	98,78
Rede05	2	5	1.597	3.714,418	99,12
Rede06	3	6	365	6.383,877	98,49
Rede07	5	6	230	7.042,630	98,33




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída peso das fêmeas na semana atual (gramas).

Contribuição de cada entrada na saída: peso das aves na semana seguinte (gramas)

Redes	Idade (sem)	Estação	Temp (°C)	URA (%)	Mortal (%)	Ração (g)	Período	Peso (g)	Unifor
Rede01	100,00	-	-	-	-	-	-	-	-
Rede02	58,71	41,29	-	-	-	-	-	-	-
Rede03	68,63	-	-	-	-	-	31,37	-	-
Rede04	68,74	-	-	-	31,26	-	-	-	-
Rede05	51,92	-	32,60	15,49	-	-	-	-	-
Rede06	-	-	-	-	-	-	-	100,00	-
Rede07	61,45	-	-	-	-	38,55	-	-	-
Rede08	50,25	-	-	-	-	20,73	29,02	-	-
Rede09	-	-	-	-	-	25,99	-	74,01	-
Rede10	37,37	27,31	-	-	-	18,93	16,39	-	-
Rede11	30,51	-	18,23	20,08	-	12,47	18,71	-	-
Rede12	-	20,37	-	-	-	12,13	18,62	48,89	-
Rede13	-	-	15,49	16,97	-	14,13	17,25	36,16	-
Rede14	-	-	14,81	10,63	11,10	11,36	12,13	29,38	10,60
Rede15	34,04	-	14,33	9,67	8,48	10,70	10,88	-	11,95
Rede16	28,17	12,01	8,47	8,14	10,81	10,22	10,60	-	11,59

Informações das redes construídas para a saída: peso das aves na semana seguinte (gramas)

Redes	Dados				
	Nent	Noc	Épocas	QME	R ²
Rede01	1	5	1.018	6.666,874	98,38
Rede02	2	5	327	7.352,020	98,21
Rede03	2	5	913	4.041,091	99,02
Rede04	2	5	1.696	6.426,282	98,19
Rede05	3	6	1.619	5.256,596	98,72
Rede06	1	5	888	4.722,976	99,40
Rede07	2	5	1.345	5.652,578	98,62
Rede08	3	6	944	3.965,684	99,04
Rede09	2	5	605	4.395,800	98,88
Rede10	4	6	557	4.778,152	98,84
Rede11	5	6	563	4.673,030	98,86
Rede12	4	6	491	3.821,425	99,02
Rede13	5	6	604	3.626,571	99,07
Rede14	7	6	984	3.145,490	98,96
Rede15	7	6	635	2.616,969	99,12
Rede16	8	6	384	3.327,060	98,88


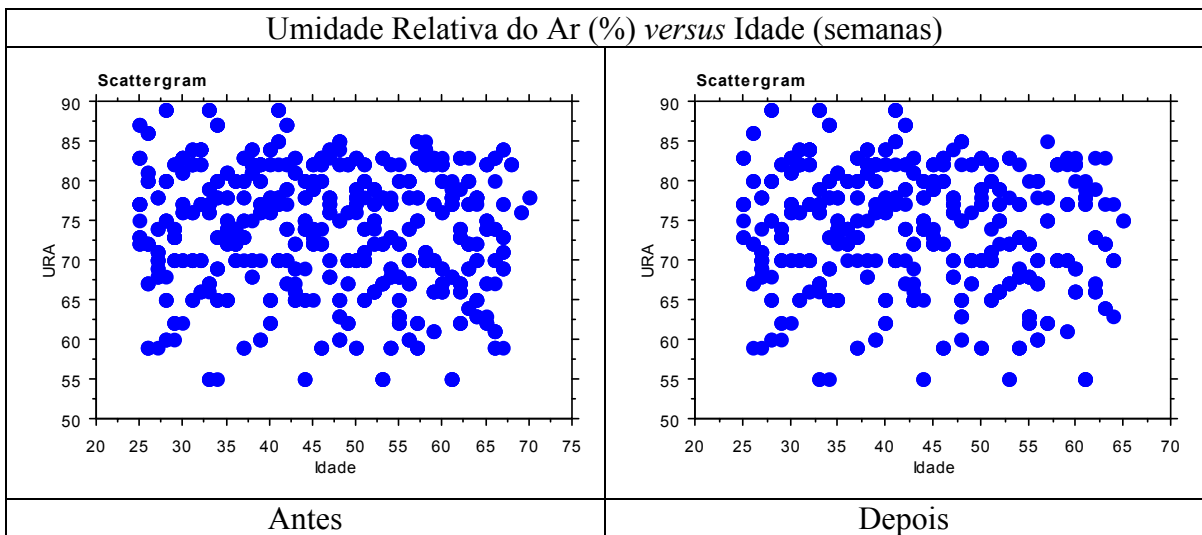
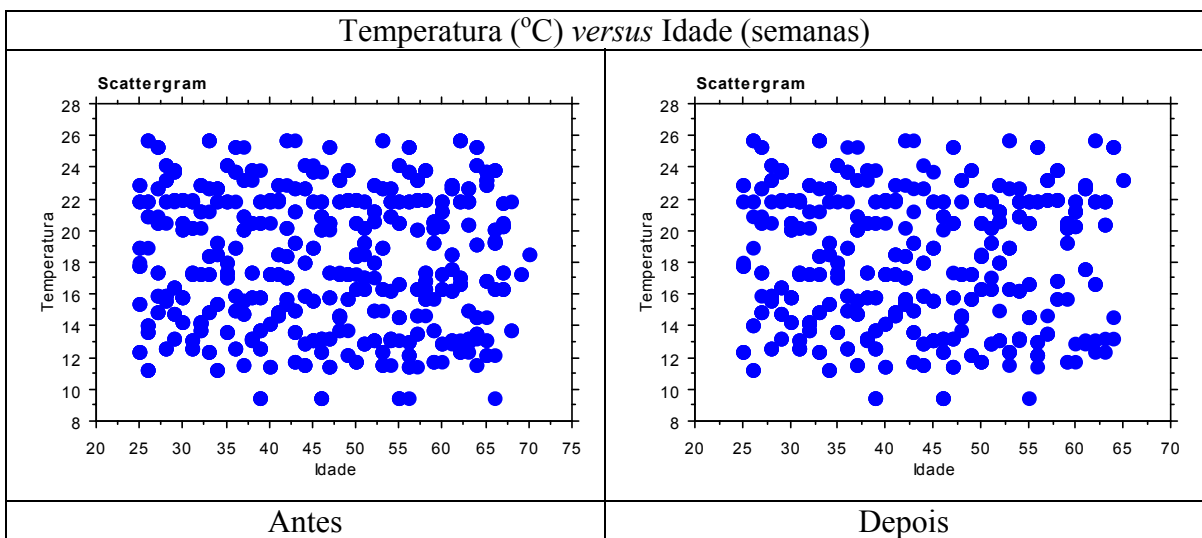
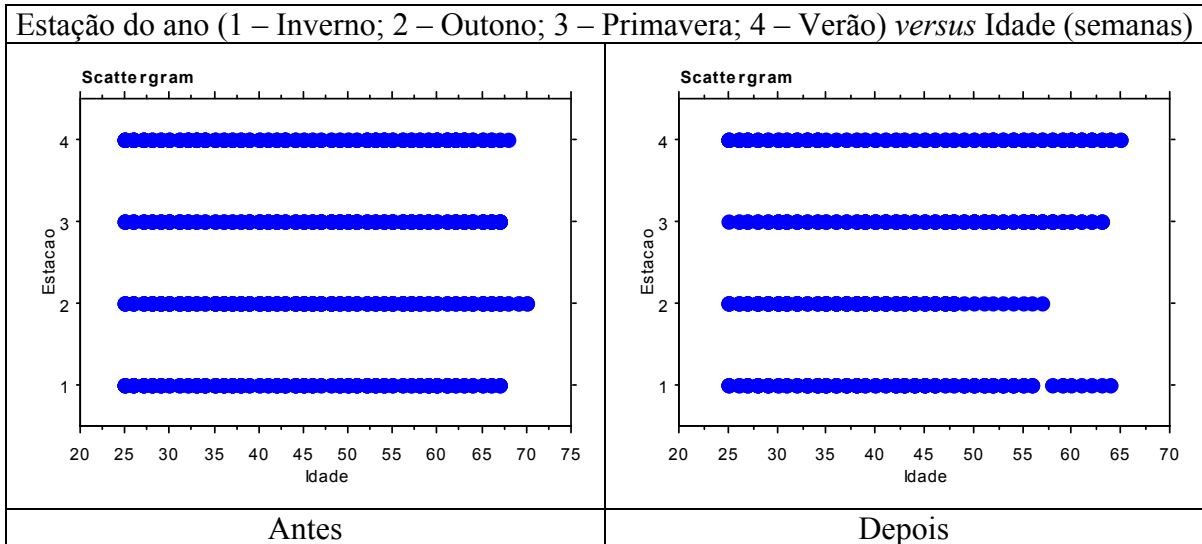
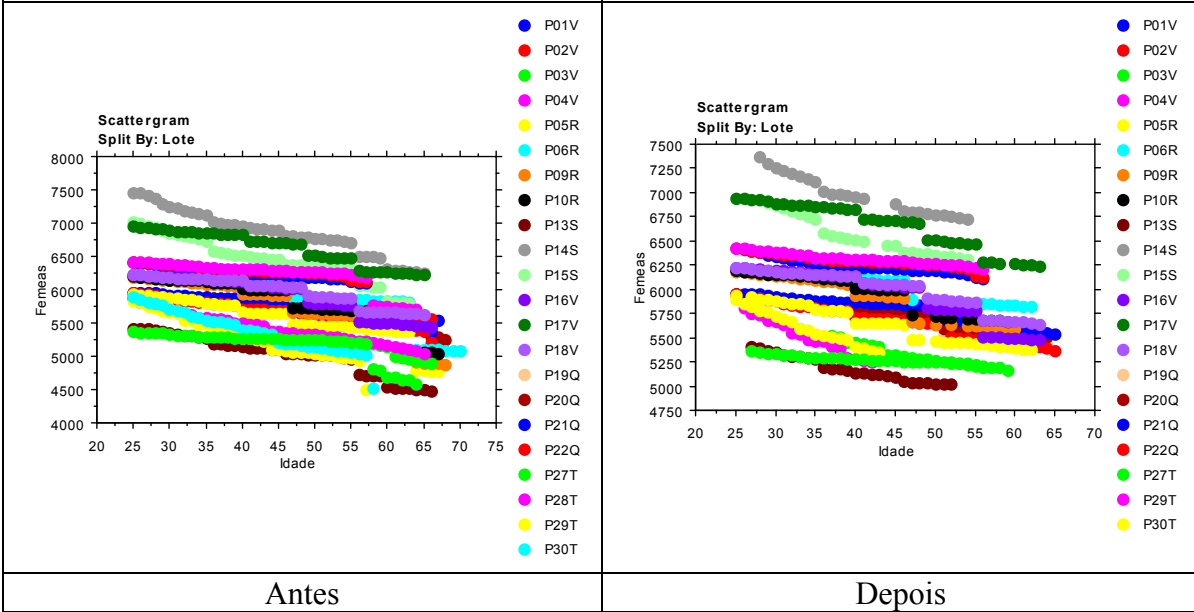


Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída peso das aves na semana seguinte (gramas).

ANEXO 3 - Análise gráfica dos dados de produção (antes e depois da eliminação de “outliers”)



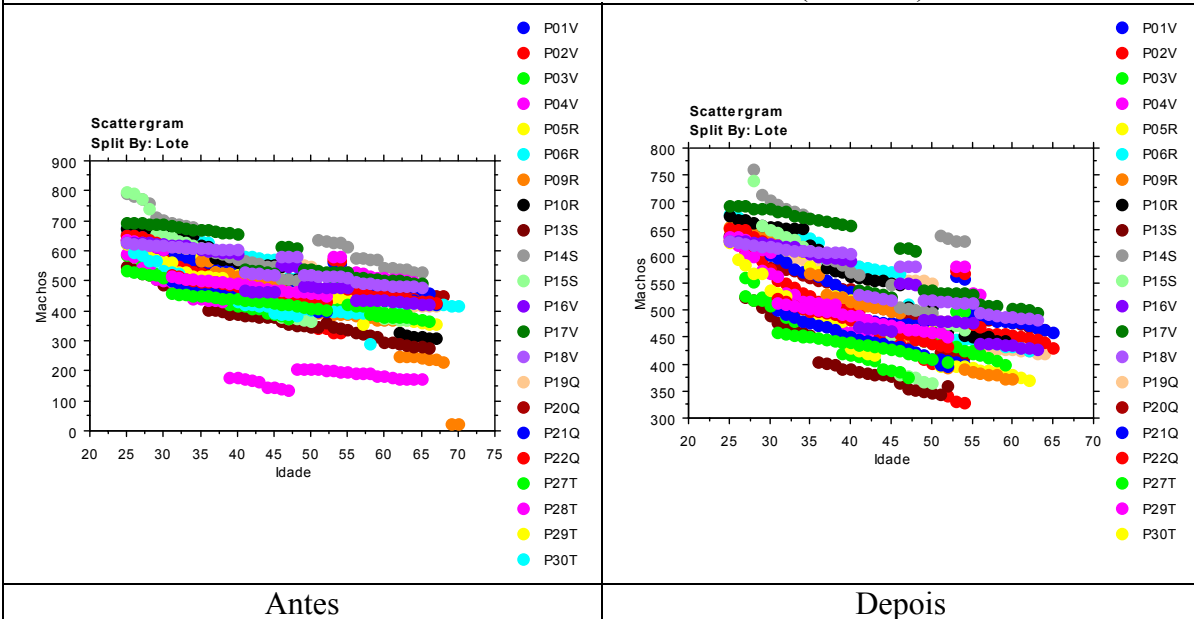
Número de fêmeas no lote *versus* Idade (semanas)



Antes

Depois

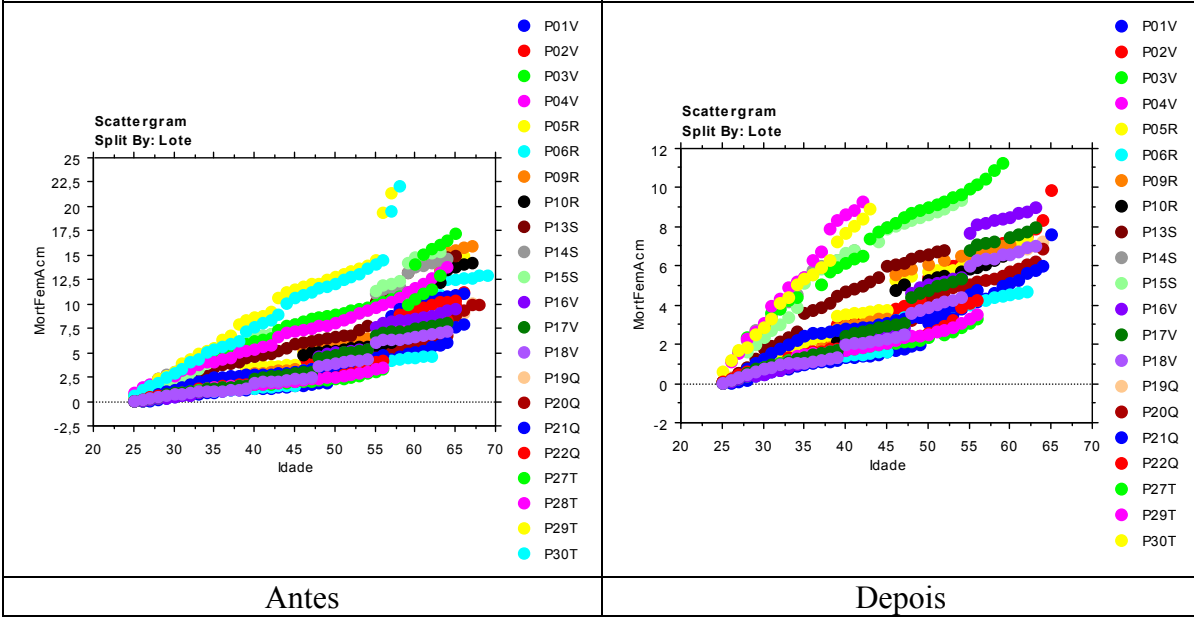
Número de machos no lote *versus* Idade (semanas)



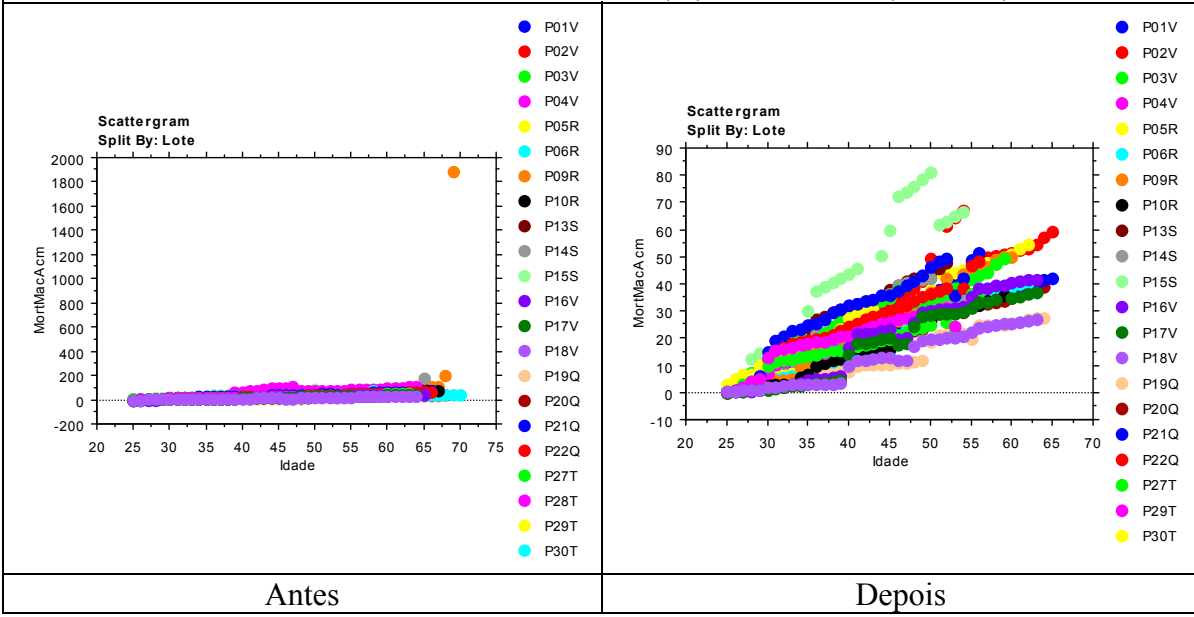
Antes

Depois


Mortalidade acumulada das fêmeas (%) versus Idade (semanas)




Mortalidade acumulada dos machos (%) versus Idade (semanas)



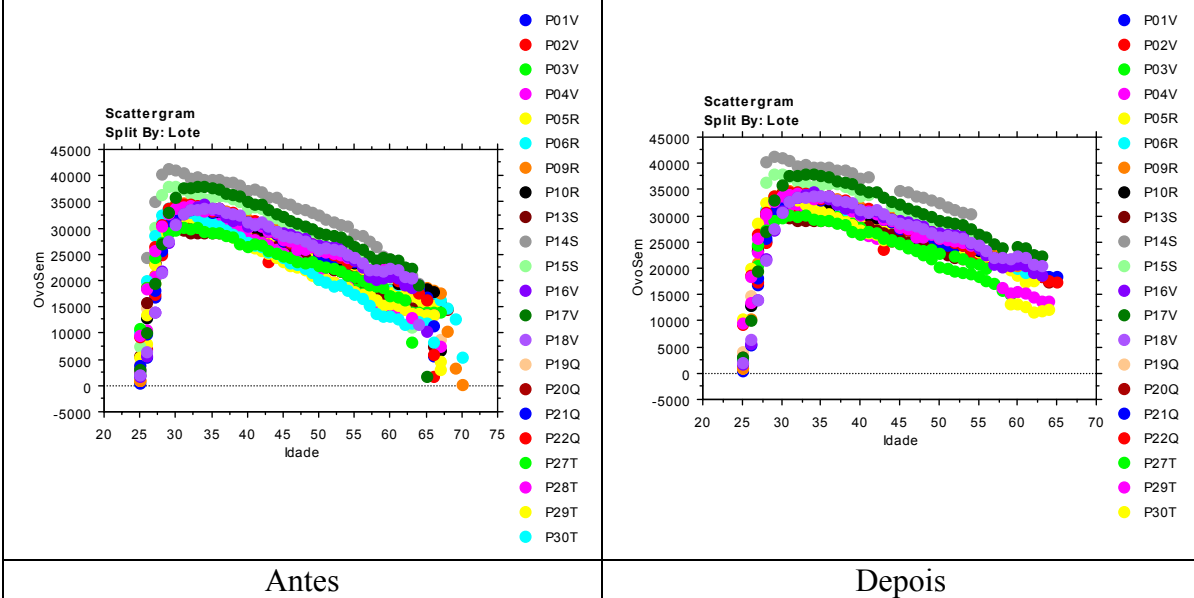
Quantidade de ração fornecida por fêmea / dia na semana atual (gramas) *versus* Idade (semanas)



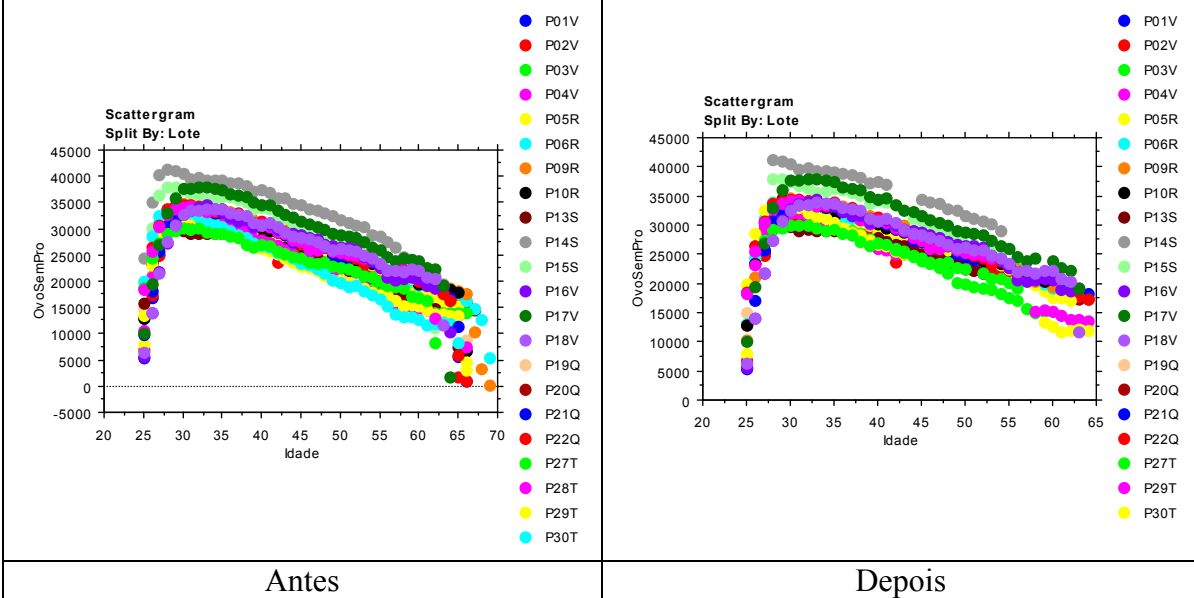
Quantidade de ração por macho / dia na semana atual (gramas) *versus* Idade (semanas)



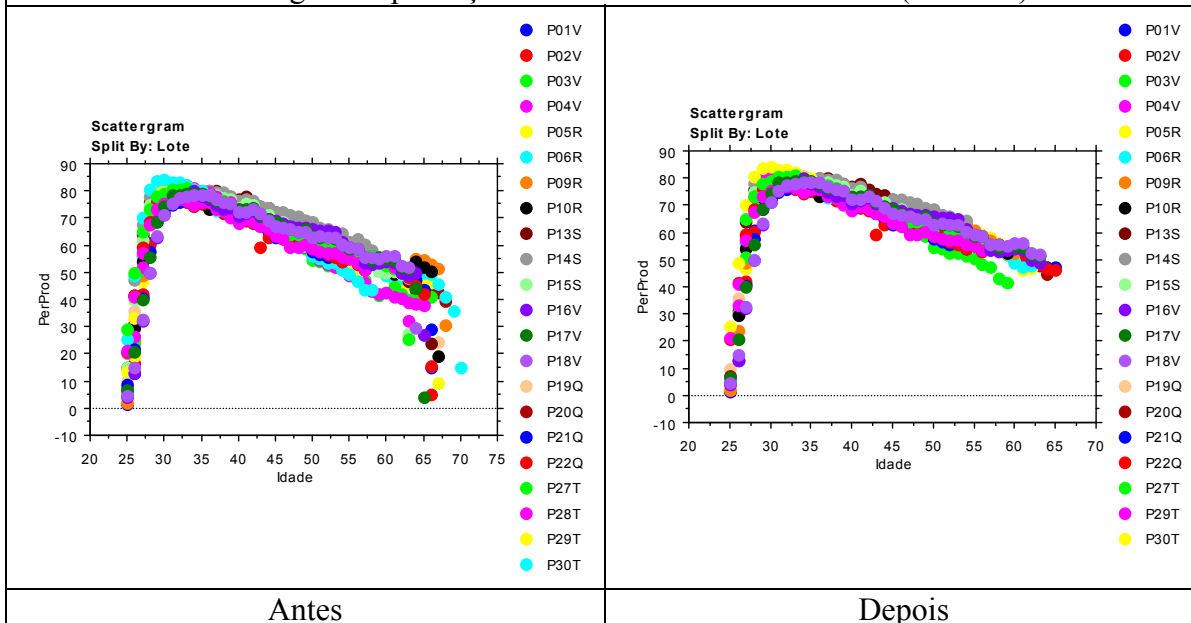
Ovos produzidos durante a semana atual *versus* Idade (semanas)



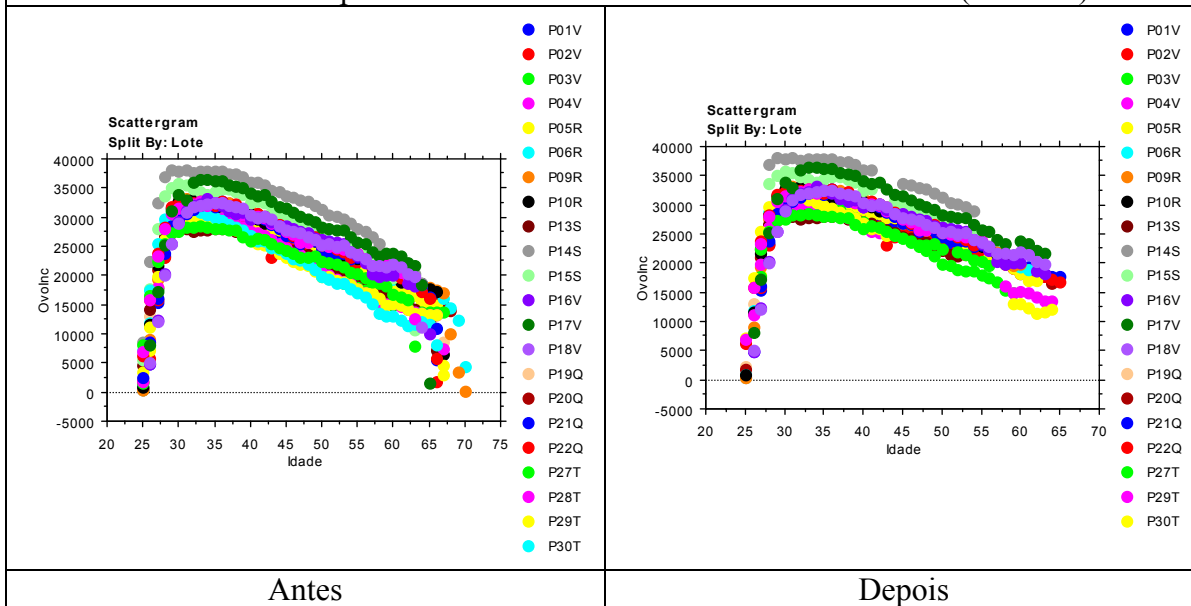
Ovos a serem produzidos na semana seguinte *versus* Idade (semanas)



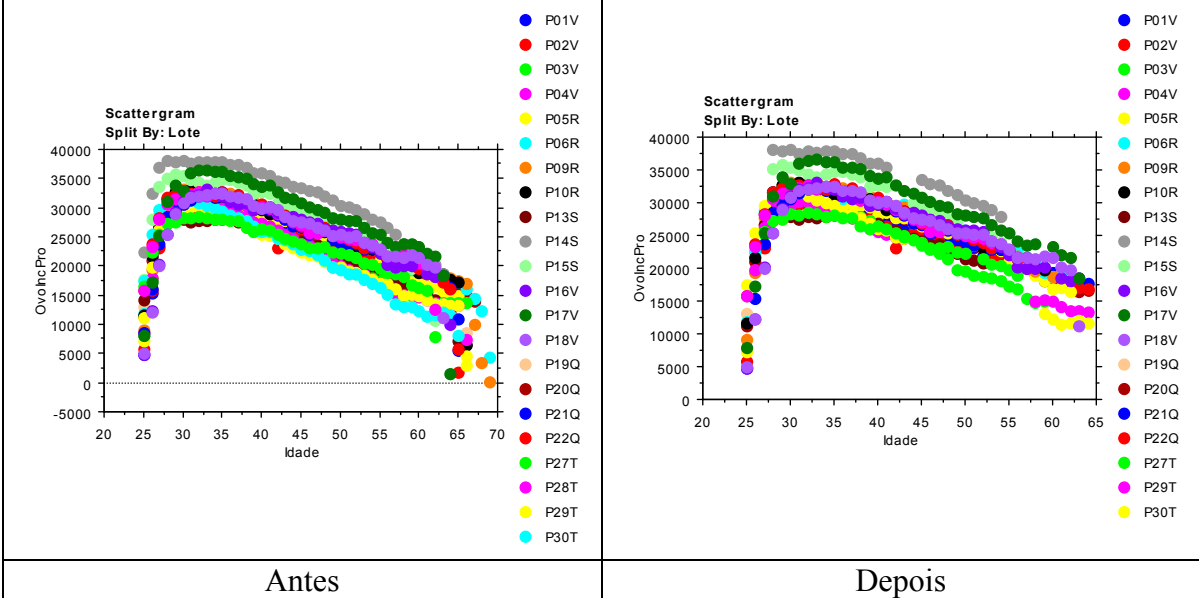
Percentagem de produção na semana atual *versus* Idade (semanas)



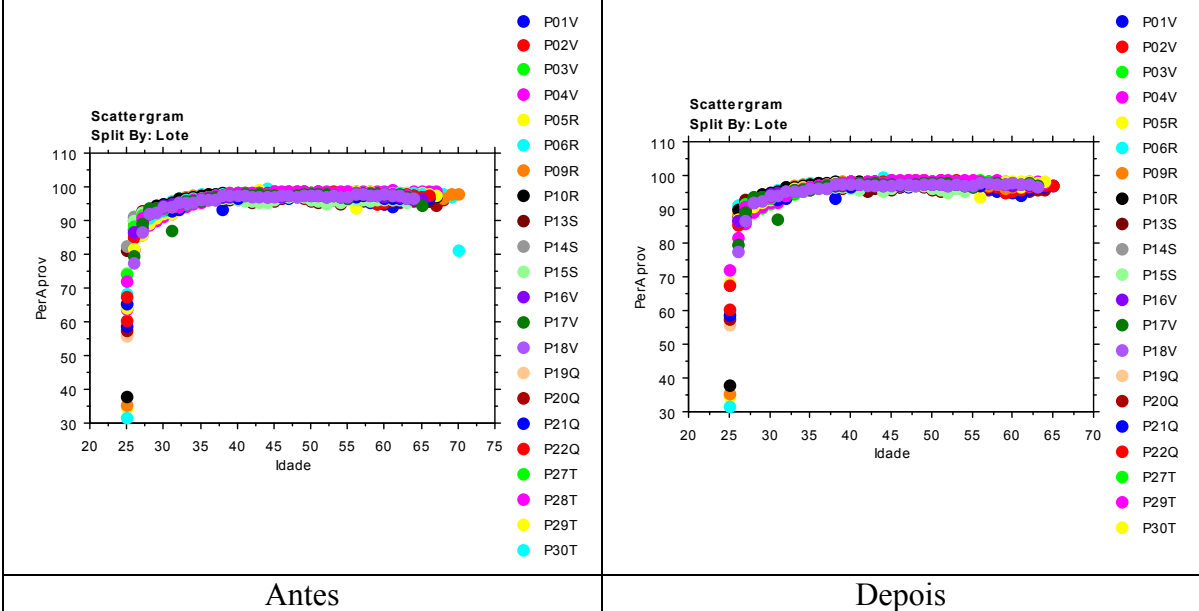
Ovos incubáveis produzidos durante a semana atual *versus* Idade (semanas)




Ovos incubáveis a serem produzidos na semana seguinte *versus* Idade (semanas)



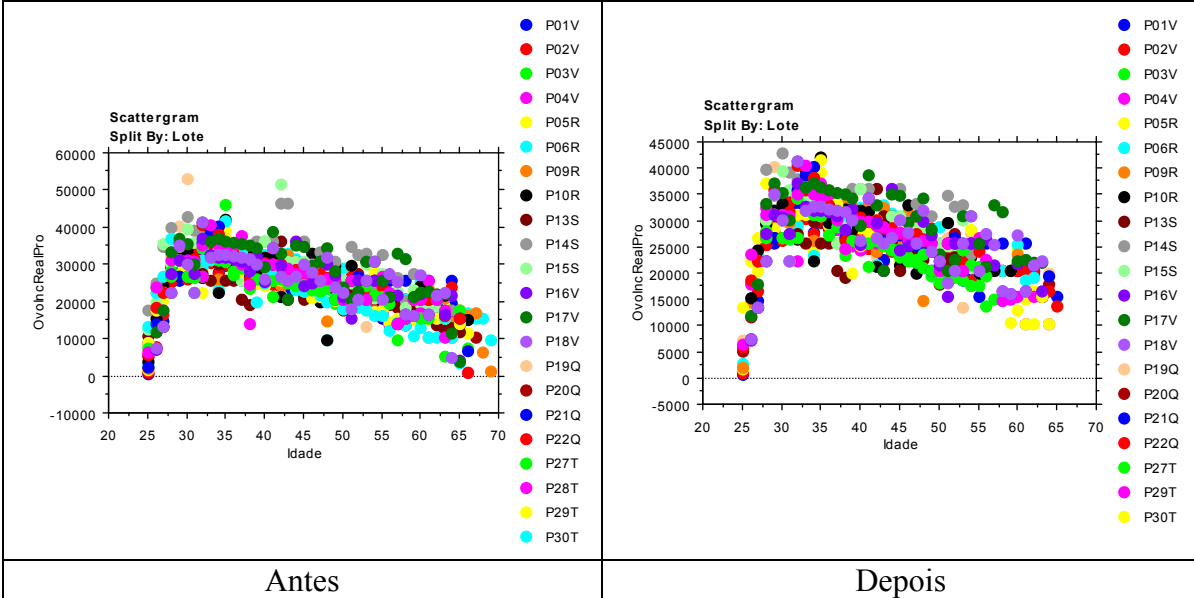
Percentagem de aproveitamento na semana atual *versus* Idade (semanas)




Ovos incubados produzidos durante a semana atual *versus* Idade (semanas)



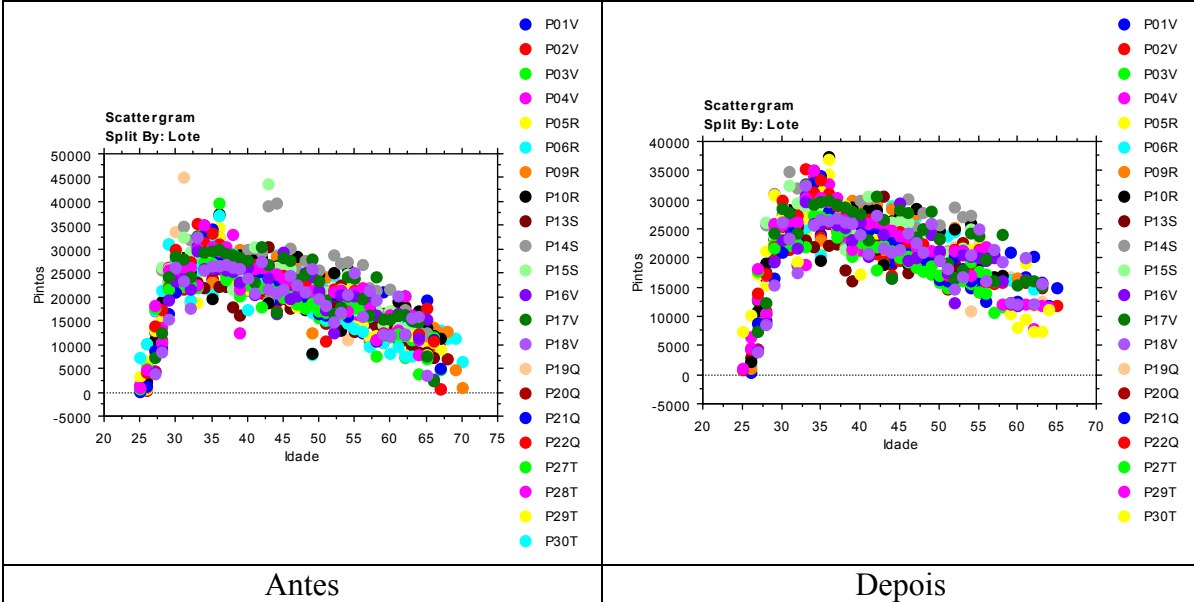
Ovos incubados a serem produzidos na semana seguinte *versus* Idade (semanas)




Percentagem de incubabilidade na semana atual *versus* Idade (semanas)




Pintos produzidos durante a semana atual *versus* Idade (semanas)



Pintos a serem produzidos na semana seguinte *versus* Idade (semanas)



Percentagem de eclosão na semana atual *versus* Idade (semanas)



ANEXO 4 - Contribuições, informações e gráficos das redes neurais artificiais geradas para o período de produção

Contribuição de cada entrada na saída: percentual de mortalidade acumulada das fêmeas

Modelos	Idade (sem)	Estação	Temp (°C)	URA (%)	Fêmeas
Rede01	100,00	-	-	-	-
Rede02	65,90	34,10	-	-	-
Rede03	60,11	-	22,68	17,21	-
Rede04	43,97	28,45	-	-	27,58
Rede05	47,80	-	16,96	13,36	21,88
Rede06	37,70	19,26	11,32	8,11	23,61

Informações das redes construídas para a saída: percentual de mortalidade acumulada das fêmeas

Modelos	Informações					
	Nent	Noc	Nsa	Épocas	QME	R ²
Rede01	1	11	16	136	3,163	50,09
Rede02	2	11	16	165	1,450	77,11
Rede03	3	11	16	104	1,631	74,27
Rede04	3	9	2	349	0,804	87,79
Rede05	4	9	2	238	1,051	84,04
Rede06	5	9	2	349	0,499	92,42




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída percentual de mortalidade acumulada das fêmeas

Contribuição de cada entrada na saída: percentual de mortalidade acumulada dos machos

Modelos	Idade (sem)	Estação	Temp (°C)	URA (%)	Machos
Rede01	100,00	-	-	-	-
Rede02	74,61	25,39	-	-	-
Rede03	55,40	-	25,37	19,23	-
Rede04	44,70	24,67	-	-	30,63
Rede05	36,96	-	18,54	14,88	29,62
Rede06	34,89	13,55	15,02	13,94	22,60

Informações das redes construídas para a saída: percentual de mortalidade acumulada dos machos

Modelos	Informações					
	Nent	Noc	Nsa	Épocas	QME	R ²
Rede01	1	11	16	136	85,438	62,75
Rede02	2	11	16	165	61,230	73,31
Rede03	3	11	16	104	64,776	71,76
Rede04	3	9	2	362	39,901	83,17
Rede05	4	9	2	110	46,886	80,22
Rede06	5	9	2	317	36,143	84,75




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída percentual de mortalidade acumulada dos machos

Contribuição de cada entrada na saída: quantidade de ração por fêmea / dia (gramas) na semana atual

Modelos	Idade (sem)	Estação	Temp (°C)	URA (%)	Fêmeas	MortFem Acm (%)
Rede01	100,00	-	-	-	-	-
Rede02	82,28	17,72	-	-	-	-
Rede03	62,06	-	20,01	17,93	-	-
Rede04	59,29	14,35	-	-	26,36	-
Rede05	54,06	-	11,14	8,41	26,39	-
Rede06	57,03	9,01	8,01	6,56	19,39	-
Rede07	39,73	10,82	8,27	6,45	14,97	19,76

Informações das redes construídas para a saída: quantidade de ração por fêmea / dia (gramas) na semana atual

Modelos	Informações					
	Nent	Noc	Nsa	Épocas	QME	R ²
Rede01	1	11	16	136	11,439	64,47
Rede02	2	11	16	165	8,348	74,07
Rede03	3	11	16	104	8,470	73,69
Rede04	3	9	2	349	5,149	87,49
Rede05	4	9	2	238	6,961	83,09
Rede06	5	9	2	349	5,419	86,84
Rede07	6	9	13	112	5,264	83,65




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída quantidade de ração por fêmea / dia (gramas) na semana atual

Contribuição de cada entrada na saída: quantidade de ração por macho / dia na semana atual (gramas)

Modelos	Idade (sem)	Estação	Temp (°C)	URA (%)	Machos	MortMac Acm (%)
Rede01	100,00	-	-	-	-	-
Rede02	74,29	25,71	-	-	-	-
Rede03	55,31	-	24,58	20,11	-	-
Rede04	44,74	28,14	-	-	27,12	-
Rede05	35,63	-	20,04	11,68	32,65	-
Rede06	29,46	20,87	16,09	13,85	19,73	-
Rede07	17,04	18,12	12,77	14,82	17,88	-

Informações das redes construídas para a saída: quantidade de ração por macho / dia na semana atual (gramas)

Modelos	Informações					
	Nent	Noc	Nsa	Épocas	QME	R ²
Rede01	1	11	16	136	226,369	63,54
Rede02	2	11	16	165	183,178	70,49
Rede03	3	11	16	104	179,573	71,08
Rede04	3	9	2	349	118,356	81,59
Rede05	4	9	2	238	144,004	77,60
Rede06	5	9	2	349	111,428	82,67
Rede07	6	9	1	289	71,934	88,81




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída quantidade de ração por macho / dia na semana atual (gramas)

Contribuição de cada entrada na saída: ovos produzidos durante a semana atual

Modelos	Idade (sem)	Estação	Temp (°C)	URA (%)	Fêmeas	Machos	MortFem Acm (%)	MortMac Acm (%)	RacDiaFem (g)	RacDiaMach (g)
Rede01	100,00	-	-	-	-	-	-	-	-	-
Rede02	79,88	20,12	-	-	-	-	-	-	-	-
Rede03	69,50	-	15,26	15,24	-	-	-	-	-	-
Rede04	41,79	9,18	7,99	6,08	16,20	-	18,76	-	-	-
Rede05	57,74	13,27	-	-	17,16	11,83	-	-	-	-
Rede06	57,04	-	7,68	7,75	16,82	10,71	-	-	-	-
Rede07	49,78	8,70	8,83	6,93	15,12	10,64	-	-	-	-
Rede08	36,40	5,93	7,84	7,99	11,01	7,15	14,90	8,78	-	-
Rede09	16,78	7,59	6,49	5,54	12,49	7,74	11,52	7,23	16,03	8,59
Rede10	28,65	-	-	-	22,62	11,28	-	-	21,71	15,74

Informações das redes construídas para a saída: ovos produzidos durante a semana atual

Modelos	Informações					
	Nent	Noc	Nsa	Épocas	QME	R ²
Rede01	1	11	16	136	7.339.738,735	75,07
Rede02	2	11	16	165	6.663.781,672	77,36
Rede03	3	11	16	104	7.004.561,782	76,21
Rede04	6	9	13	112	2.081.968,802	92,93
Rede05	4	10	12	130	2.028.269,132	93,11
Rede06	5	11	12	107	2.283.248,003	92,24
Rede07	6	11	12	182	1.900.994,200	93,54
Rede08	8	11	12	167	1.775.723,995	93,97
Rede09	10	11	12	150	1.071.356,930	96,36
Rede10	5	11	12	107	1.713.663,563	94,18




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída ovos produzidos durante a semana atual

Contribuição de cada entrada na saída: ovos a serem produzidos na semana seguinte

Modelos	Idade (sem)	Estação	Temp (°C)	URA (%)	Fêmeas	Machos	MortFem Acm (%)	MortMac Acm (%)	RacDiaFem (g)	RacDiaMac (g)	OvoSem
Rede01	100,00	-	-	-	-	-	-	-	-	-	-
Rede02	76,48	23,52	-	-	-	-	-	-	-	-	-
Rede03	58,19	-	22,87	18,94	-	-	-	-	-	-	-
Rede04	39,91	10,12	7,39	5,71	16,87	-	20,00	-	-	-	-
Rede05	52,07	15,70	-	-	18,82	13,41	-	-	-	-	-
Rede06	52,30	-	7,60	8,66	19,63	11,81	-	-	-	-	-
Rede07	46,17	9,58	8,32	7,32	17,47	11,14	-	-	-	-	-
Rede08	33,10	6,67	8,45	8,46	12,06	7,12	14,59	9,55	-	-	-
Rede09	15,32	8,39	6,00	6,16	12,47	6,75	11,51	7,37	16,45	9,58	-
Rede10	25,56	-	-	-	20,87	10,64	-	-	24,67	18,26	-
Rede11	13,59	6,56	6,04	5,71	10,42	6,85	7,50	8,36	8,12	7,59	19,26
Rede12	37,05	-	-	-	-	-	-	-	-	-	62,95
Rede13	23,50	10,81	11,18	8,43	-	-	-	-	-	-	46,08
Rede14	32,97	-	12,01	13,18	-	-	-	-	-	-	41,84
Rede15	16,06	7,45	9,25	8,77	11,74	-	7,33	-	11,05	-	28,35

Informações das redes construídas para a saída: ovos a serem produzidos na semana seguinte

Modelos	Informações					
	Nent	Noc	Nsa	Épocas	QME	R ²
Rede01	1	11	16	136	6.461.762,513	75,13
Rede02	2	11	16	165	5.340.537,943	79,45
Rede03	3	11	16	104	6.266.087,446	75,88
Rede04	6	9	13	112	1.264.896,283	95,13
Rede05	4	10	12	130	1.453.383,485	94,41
Rede06	5	11	12	107	1.478.954,604	94,31
Rede07	6	11	12	182	1.262.520,287	95,14
Rede08	8	11	12	167	1.037.144,494	96,01
Rede09	10	11	12	150	712.064,196	97,26
Rede10	5	11	12	107	1.196.222,567	95,40
Rede11	11	11	11	75	506.702,564	98,05
Rede12	2	10	11	163	582.490,724	97,76
Rede13	5	10	11	258	457.969,438	98,24
Rede14	4	10	11	111	611.518,886	97,65
Rede15	8	11	11	258	377.954,975	98,55




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída ovos a serem produzidos na semana seguinte

Contribuição de cada entrada na saída: percentagem de produção na semana atual

Modelos	Idade (sem)	Estação	Temp (°C)	URA (%)	Fêmeas	Machos	MortFem Acm (%)	MortMac Acm (%)	RacDiaFem (g)	RacDiaMac (g)	OvoSem
Rede01	100,00	-	-	-	-	-	-	-	-	-	-
Rede02	81,24	18,76	-	-	-	-	-	-	-	-	-
Rede03	72,01	-	14,36	13,63	-	-	-	-	-	-	-
Rede04	44,81	8,66	8,96	5,94	11,95	-	19,68	-	-	-	-
Rede05	57,75	11,68	-	-	17,71	12,86	-	-	-	-	-
Rede06	55,71	-	7,83	7,96	17,21	11,29	-	-	-	-	-
Rede07	49,48	9,68	8,83	7,62	13,93	10,46	-	-	-	-	-
Rede08	36,22	6,62	7,00	7,78	11,97	6,77	15,58	8,06	-	-	-
Rede09	16,33	8,22	6,53	5,57	11,38	7,93	11,50	6,89	17,50	8,15	-
Rede10	28,08	-	-	-	19,14	11,94	-	-	24,31	16,53	-
Rede11	11,55	6,49	7,14	5,17	10,95	5,78	8,41	7,40	9,09	8,39	19,63
Rede12	39,69	-	-	-	-	-	-	-	-	-	60,31
Rede13	31,07	10,65	9,97	8,42	-	-	-	-	-	-	39,89
Rede14	36,12	-	13,64	11,98	-	-	-	-	-	-	38,26
Rede15	17,83	8,60	9,22	7,63	12,10	-	7,32	-	9,18	-	28,12

Informações das redes construídas para a saída: percentagem de produção na semana atual

Modelos	Informações					
	Nent	Noc	Nsa	Épocas	QME	R ²
Rede01	1	11	16	136	17,475	85,75
Rede02	2	11	16	165	18,481	84,93
Rede03	3	11	16	104	14,616	88,08
Rede04	6	9	13	112	10,755	91,23
Rede05	4	10	12	130	11,334	90,76
Rede06	5	11	12	107	11,825	90,36
Rede07	6	11	12	182	10,347	91,56
Rede08	8	11	12	167	9,992	91,85
Rede09	10	11	12	150	6,403	94,78
Rede10	5	11	12	107	9,493	92,26
Rede11	11	11	11	75	1,470	98,80
Rede12	2	10	11	163	6,555	94,66
Rede13	5	10	11	258	5,146	95,80
Rede14	4	10	11	111	5,420	95,58
Rede15	8	11	11	258	1,064	99,13




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída percentagem de produção na semana atual

Contribuição de cada entrada na saída: ovos incubáveis produzidos durante a semana atual

Modelos	Idade (sem)	Estação	Temp (°C)	URA (%)	Fêmeas	Machos	MortFem Acm (%)	MortMac Acm (%)	RacDiaFem (g)	RacDiaMach (g)	OvoSem
Rede01	100,00	-	-	-	-	-	-	-	-	-	-
Rede02	78,87	21,13	-	-	-	-	-	-	-	-	-
Rede03	70,58	-	16,03	13,39	-	-	-	-	-	-	-
Rede04	44,17	8,75	8,18	5,34	13,92	-	19,64	-	-	-	-
Rede05	58,86	12,03	-	-	17,41	11,70	-	-	-	-	-
Rede06	56,88	-	6,84	7,31	17,69	11,28	-	-	-	-	-
Rede07	48,29	8,27	8,08	7,29	17,58	10,49	-	-	-	-	-
Rede08	36,75	6,58	7,19	7,49	11,32	6,31	14,92	9,44	-	-	-
Rede09	16,75	8,32	5,79	4,53	12,57	7,39	11,20	6,25	18,20	9,00	-
Rede10	28,23	-	-	-	21,02	11,31	-	-	25,04	14,40	-
Rede11	13,39	6,12	5,58	5,36	9,75	6,76	7,37	7,01	8,46	7,65	22,55
Rede12	34,80	-	-	-	-	-	-	-	-	-	65,20
Rede13	25,35	10,94	9,12	9,64	-	-	-	-	-	-	44,95
Rede14	33,28	-	13,68	12,50	-	-	-	-	-	-	40,54
Rede15	14,89	6,71	9,05	8,36	10,90	-	7,51	-	10,20	-	32,38

Informações das redes construídas para a saída: ovos incubáveis produzidos durante a semana atual

Modelos	Informações					
	Nent	Noc	Nsa	Épocas	QME	R ²
Rede01	1	11	16	136	6.623.423,322	75,93
Rede02	2	11	16	165	6.068.549,307	77,95
Rede03	3	11	16	104	6.365.002,684	76,87
Rede04	6	9	13	112	2.001.726,583	92,73
Rede05	4	10	12	130	1.810.299,552	93,42
Rede06	5	11	12	107	2.059.640,469	92,51
Rede07	6	11	12	182	1.677.439,356	93,90
Rede08	8	11	12	167	1.639.082,187	94,04
Rede09	10	11	12	150	1.015.756,283	96,31
Rede10	5	11	12	107	1.501.264,068	94,54
Rede11	11	11	11	75	345.162,595	98,75
Rede12	2	10	11	163	164.901,669	99,40
Rede13	5	10	11	258	176.430,766	99,36
Rede14	4	10	11	111	182.542,635	99,34
Rede15	8	11	11	258	180.869,763	99,34




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída ovos incubáveis produzidos durante a semana atual

Contribuição de cada entrada na saída: ovos incubáveis a serem produzidos na semana seguinte

Modelos	Idade (sem)	Estação	Temp (°C)	URA (%)	Fêmeas	Machos	MortFemAcm (%)	MortMachAcm (%)	RacDiaFem (g)	RacDiaMach (g)	OvoSem	OvoInc
Rede01	100,00	-	-	-	-	-	-	-	-	-	-	-
Rede02	77,75	22,25	-	-	-	-	-	-	-	-	-	-
Rede03	63,87	-	20,70	15,43	-	-	-	-	-	-	-	-
Rede04	42,29	8,97	8,60	5,06	15,14	-	19,94	-	-	-	-	-
Rede05	55,29	12,54	-	-	17,57	14,60	-	-	-	-	-	-
Rede06	54,12	-	6,93	8,75	19,35	10,85	-	-	-	-	-	-
Rede07	46,14	9,69	9,74	7,83	15,65	10,95	-	-	-	-	-	-
Rede08	34,83	6,80	8,76	7,74	11,84	6,57	13,90	9,56	-	-	-	-
Rede09	17,79	8,86	6,06	6,04	10,74	6,86	10,74	7,60	14,91	10,40	-	-
Rede10	25,91	-	-	-	22,58	10,93	-	-	24,34	16,24	-	-
Rede11	12,52	6,60	6,66	5,76	10,17	6,70	8,29	8,23	9,02	8,25	17,80	-
Rede12	34,56	-	-	-	-	-	-	-	-	-	65,44	-
Rede13	25,31	12,45	11,68	8,99	-	-	-	-	-	-	41,57	-
Rede14	32,70	-	-	13,00	12,62	-	-	-	-	-	41,68	-
Rede15	22,22	12,78	9,55	9,86	-	-	-	-	-	-	21,63	23,96
Rede16	34,89	-	-	-	-	-	-	-	-	-	38,54	26,57
Rede17	15,77	8,39	8,67	9,74	11,70	-	8,01	-	10,25	-	27,47	-

Informações das redes construídas para a saída: ovos incubáveis a serem produzidos na semana seguinte

Modelos	Informações					
	Nent	Noc	Nsa	Épocas	QME	R ²
Rede01	1	11	16	136	5.872.223,536	74,73
Rede02	2	11	16	165	4.874.586,850	79,03
Rede03	3	11	16	104	5.630.233,799	75,77
Rede04	6	9	13	112	1.239.703,214	94,67
Rede05	4	10	12	130	1.300.946,016	94,40
Rede06	5	11	12	107	1.341.675,088	94,23
Rede07	6	11	12	182	1.125.004,392	95,16
Rede08	8	11	12	167	989.277,500	95,74
Rede09	10	11	12	150	715.985,539	96,92
Rede10	5	11	12	107	1.160.970,143	95,00
Rede11	11	11	11	75	450.217,883	98,06
Rede12	2	10	11	163	626.320,362	97,31
Rede13	5	10	11	258	476.521,652	97,95
Rede14	4	10	11	111	620.849,653	97,33
Rede15	6	10	8	112	624.640,510	97,63
Rede16	3	10	8	116	624.028,778	97,63
Rede17	8	11	11	258	406.542,258	98,25




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída ovos incubáveis a serem produzidos na semana seguinte

Contribuição de cada entrada na saída: percentagem de aproveitamento na semana atual

Modelos	Idade (sem)	Estação	Temp (°C)	URA (%)	Fêmeas	Machos	MortFemAcm (%)	MortMachAcm (%)	RacDiaFem (g)	RacDiaMach (g)	OvoSem	OvoInc
Rede01	100,00	-	-	-	-	-	-	-	-	-	-	-
Rede02	79,13	20,87	-	-	-	-	-	-	-	-	-	-
Rede03	57,71	-	23,03	19,26	-	-	-	-	-	-	-	-
Rede04	44,34	10,17	9,26	6,67	13,40	-	16,16	-	-	-	-	-
Rede05	49,63	13,01	-	-	19,79	17,57	-	-	-	-	-	-
Rede06	50,99	-	10,93	7,93	17,13	13,02	-	-	-	-	-	-
Rede07	41,34	7,06	8,54	9,18	21,12	12,76	-	-	-	-	-	-
Rede08	35,23	7,79	9,25	7,53	11,10	6,69	11,75	10,66	-	-	-	-
Rede09	16,57	10,15	8,14	6,95	9,47	7,59	10,50	7,07	14,03	9,53	-	-
Rede10	26,65	-	-	-	17,92	11,06	-	-	23,63	20,74	-	-
Rede11	12,88	5,68	7,23	5,81	11,26	6,11	8,37	9,40	9,56	8,93	14,77	-
Rede12	43,05	-	-	-	-	-	-	-	-	-	56,95	-
Rede13	23,13	15,43	15,02	10,52	-	-	-	-	-	-	35,90	-
Rede14	35,51	-	14,81	13,33	-	-	-	-	-	-	36,35	-
Rede15	21,20	14,28	11,12	11,35	-	-	-	-	-	-	21,48	20,57
Rede16	43,65	-	-	-	-	-	-	-	-	-	28,77	27,58
Rede17	17,52	11,17	7,65	11,10	11,17	-	9,42	-	10,33	-	21,64	-

Informações das redes construídas para a saída: percentagem de aproveitamento na semana atual

Modelos	Informações					
	Nent	Noc	Nsa	Épocas	QME	R ²
Rede01	1	11	16	136	1,959	77,77
Rede02	2	11	16	165	1,809	79,48
Rede03	3	11	16	104	2,226	74,75
Rede04	6	9	13	112	2,467	72,01
Rede05	4	10	12	130	1,737	80,29
Rede06	5	11	12	107	1,895	78,50
Rede07	6	11	12	182	1,698	80,73
Rede08	8	11	12	167	1,924	78,17
Rede09	10	11	12	150	1,596	81,89
Rede10	5	11	12	107	1,750	80,14
Rede11	11	11	11	75	2,115	76,00
Rede12	2	10	11	163	2,043	76,82
Rede13	5	10	11	258	0,941	89,20
Rede14	4	10	11	111	1,992	77,41
Rede15	6	10	8	112	1,501	82,78
Rede16	3	10	8	116	1,913	78,06
Rede17	8	11	11	258	1,439	83,67




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída percentagem de aproveitamento na semana atual

Contribuição de cada entrada na saída: ovos incubados produzidos na semana atual

Modelos	Idade (sem)	Estação	Temp (°C)	URA (%)	Fêmeas	Machos	MortFemAcm (%)	MortMachAcm (%)	RacDiaFem (g)	RacDiaMach (g)	OvoSem	OvoInc
Rede01	100,00	-	-	-	-	-	-	-	-	-	-	-
Rede02	83,12	16,88	-	-	-	-	-	-	-	-	-	-
Rede03	65,60	-	17,54	16,86	-	-	-	-	-	-	-	-
Rede04	44,98	9,55	8,89	6,57	12,03	-	17,98	-	-	-	-	-
Rede05	61,52	11,68	-	-	16,02	10,78	-	-	-	-	-	-
Rede06	55,64	-	7,55	7,67	17,37	11,77	-	-	-	-	-	-
Rede07	48,34	7,89	8,45	7,79	17,48	10,05	-	-	-	-	-	-
Rede08	38,34	6,81	8,55	8,67	9,09	6,65	13,66	8,23	-	-	-	-
Rede09	18,35	7,50	6,62	6,51	9,39	6,60	11,54	8,01	16,40	9,08	-	-
Rede10	28,33	-	-	-	19,58	11,35	-	-	24,38	16,36	-	-
Rede11	13,33	6,61	6,01	6,26	8,55	6,65	8,57	8,49	9,51	8,09	17,93	-
Rede12	36,46	-	-	-	-	-	-	-	-	-	63,54	-
Rede13	26,45	16,05	14,11	10,24	-	-	-	-	-	-	33,15	-
Rede14	32,22	-	14,19	13,97	-	-	-	-	-	-	39,62	-
Rede15	21,46	13,18	11,90	10,96	-	-	-	-	-	-	19,20	23,30
Rede16	35,58	-	-	-	-	-	-	-	-	-	33,07	31,35
Rede17	18,68	9,51	9,45	10,32	10,79	-	8,63	-	9,36	-	23,26	-

Informações das redes construídas para a saída: ovos incubados produzidos na semana atual

Modelos	Informações					
	Nent	Noc	Nsa	Épocas	QME	R ²
Rede01	1	11	16	136	18.261.726,967	59,73
Rede02	2	11	16	165	18.133.663,930	60,02
Rede03	3	11	16	104	17.966.131,551	60,39
Rede04	6	9	13	112	11.467.466,190	74,72
Rede05	4	10	12	130	13.510.056,110	70,21
Rede06	5	11	12	107	13.020.918,946	71,29
Rede07	6	11	12	182	11.629.145,513	74,36
Rede08	8	11	12	167	10.747.105,456	76,30
Rede09	10	11	12	150	11.031.705,813	75,68
Rede10	5	11	12	107	13.041.383,571	71,24
Rede11	11	11	11	75	10.996.816,942	75,75
Rede12	2	10	11	163	11.951.329,101	73,65
Rede13	5	10	11	258	10.418.940,488	77,03
Rede14	4	10	11	111	11.520.635,387	74,60
Rede15	6	10	8	112	10.869.880,812	77,23
Rede16	3	10	8	116	11.873.714,917	75,13
Rede17	8	11	11	258	9.806.353,607	78,38




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída ovos incubados produzidos na semana atual

Contribuição de cada entrada na saída: ovos incubados a serem produzidos na semana seguinte

Modelos	Idade (sem)	Estação	Temp (°C)	URA (%)	Fêmeas	Machos	MortFe mAcM (%)	MortMacAcM (%)	RacDia Fem (g)	RacDia Mac (g)	OvoSem	OvoInc	OvoInc Real
Rede01	100,00	-	-	-	-	-	-	-	-	-	-	-	-
Rede02	83,13	16,87	-	-	-	-	-	-	-	-	-	-	-
Rede03	64,26	-	19,50	16,24	-	-	-	-	-	-	-	-	-
Rede04	45,87	8,71	8,24	5,57	12,06	-	19,55	-	-	-	-	-	-
Rede05	59,65	9,10	-	-	17,93	13,32	-	-	-	-	-	-	-
Rede06	56,15	-	7,44	7,82	17,23	11,36	-	-	-	-	-	-	-
Rede07	45,14	9,66	8,49	8,14	18,02	10,55	-	-	-	-	-	-	-
Rede08	35,06	6,45	9,94	8,74	10,97	6,98	12,73	9,13	-	-	-	-	-
Rede09	14,11	9,66	6,74	7,35	11,90	7,33	10,42	7,42	15,73	9,34	-	-	-
Rede10	27,82	-	-	-	20,07	12,29	-	-	23,05	16,77	-	-	-
Rede11	11,16	7,00	5,83	6,00	10,58	6,57	9,61	9,33	9,29	7,95	16,68	-	-
Rede12	33,99	-	-	-	-	-	-	-	-	-	66,01	-	-
Rede13	21,98	18,19	12,37	11,84	-	-	-	-	-	-	35,62	-	-
Rede14	31,31	-	14,68	13,13	-	-	-	-	-	-	40,88	-	-
Rede15	19,84	13,53	11,73	11,47	-	-	-	-	-	-	20,35	23,08	-
Rede16	40,69	-	-	-	-	-	-	-	-	-	33,58	25,73	-
Rede17	26,00	-	-	-	-	-	-	-	-	-	39,16	-	34,84
Rede18	5,64	7,64	6,70	7,61	8,80	6,87	6,64	5,88	6,14	7,00	7,64	9,49	13,95
Rede19	13,27	8,39	7,05	9,69	7,53	7,67	7,16	7,26	10,21	8,07	-	-	13,70
Rede20	49,36	-	-	-	-	-	-	-	-	-	-	-	50,64
Rede21	27,53	9,66	14,97	12,86	-	-	-	-	-	-	-	-	34,98
Rede22	14,31	10,62	7,97	11,10	11,17	-	9,95	-	11,00	-	23,88	-	-

Informações das redes construídas para a saída: ovos incubados a serem produzidos na semana seguinte

Modelos	Informações					R ²
	Nent	Noc	Nsa	Épocas	QME	
Rede01	1	11	16	136	17.451.094,206	52,60
Rede02	2	11	16	165	17.260.811,110	53,12
Rede03	3	11	16	104	17.144.979,406	53,43
Rede04	6	9	13	112	12.473.487,308	66,12
Rede05	4	10	12	130	13.250.413,862	64,01
Rede06	5	11	12	107	13.643.108,991	62,94
Rede07	6	11	12	182	12.396.072,529	66,33
Rede08	8	11	12	167	12.223.605,779	66,80
Rede09	10	11	12	150	12.082.195,526	67,18
Rede10	5	11	12	107	13.521.320,170	63,27
Rede11	11	11	11	75	11.718.730,128	68,17
Rede12	2	10	11	163	12.317.220,612	66,54
Rede13	5	10	11	258	11.996.389,451	67,42
Rede14	4	10	11	111	12.162.765,870	66,96
Rede15	6	10	8	112	11.839.622,861	70,29
Rede16	3	10	8	116	12.725.339,075	68,06
Rede17	3	9	5	84	12.322.303,012	69,35
Rede18	13	11	5	94	10.566.545,758	71,54
Rede19	11	10	5	223	11.247.903,636	69,78
Rede20	2	9	5	132	16.659.949,922	58,56
Rede21	5	9	5	59	16.205.004,365	59,69
Rede22	8	11	11	258	11.076.276,787	69,91




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída ovos incubados a serem produzidos na semana seguinte

Contribuição de cada entrada na saída: percentagem de incubabilidade na semana atual

Modelos	Idade (sem)	Estação	Temp (°C)	URA (%)	Fêmeas	Machos	MortFe mAcM (%)	MortMacAcM (%)	RacDia Fem (g)	RacDia Mac (g)	OvoSem	OvoInc	OvoInc Real
Rede01	100,00	-	-	-	-	-	-	-	-	-	-	-	-
Rede02	82,87	17,13	-	-	-	-	-	-	-	-	-	-	-
Rede03	61,23	-	20,41	18,36	-	-	-	-	-	-	-	-	-
Rede04	43,95	9,96	11,91	7,68	8,80	-	17,70	-	-	-	-	-	-
Rede05	55,84	12,25	-	-	19,49	12,42	-	-	-	-	-	-	-
Rede06	55,68	-	7,17	8,42	18,30	10,43	-	-	-	-	-	-	-
Rede07	42,19	10,20	11,02	8,14	17,39	11,06	-	-	-	-	-	-	-
Rede08	34,34	7,82	10,00	9,13	9,71	7,33	12,20	9,47	-	-	-	-	-
Rede09	17,74	7,85	8,03	8,16	7,51	5,93	10,84	9,43	14,25	10,26	-	-	-
Rede10	30,20	-	-	-	18,57	10,08	-	-	24,48	16,67	-	-	-
Rede11	13,52	6,36	7,01	6,18	9,49	7,24	8,49	8,47	9,16	7,94	16,14	-	-
Rede12	42,72	-	-	-	-	-	-	-	-	-	57,28	-	-
Rede13	27,64	17,58	15,22	11,33	-	-	-	-	-	-	28,23	-	-
Rede14	36,58	-	13,42	12,45	-	-	-	-	-	-	37,55	-	-
Rede15	24,95	13,72	12,59	11,60	-	-	-	-	-	-	19,05	18,09	-
Rede16	40,49	-	-	-	-	-	-	-	-	-	29,67	29,84	-
Rede17	25,46	-	-	-	-	-	-	-	-	-	37,42	-	37,12
Rede18	6,25	5,25	5,56	7,43	7,67	6,16	6,26	5,30	5,82	6,85	9,40	10,27	17,78
Rede19	9,24	5,20	6,88	8,83	9,68	6,67	5,81	7,41	10,96	10,94	-	-	18,38
Rede20	43,81	-	-	-	-	-	-	-	-	-	-	-	56,19
Rede21	27,23	10,94	14,88	12,49	-	-	-	-	-	-	-	-	34,46
Rede22	17,95	9,91	10,43	10,32	10,27	-	9,03	-	11,19	-	20,90	-	-

Informações das redes construídas para a saída: percentagem de incubabilidade na semana atual

Modelos	Informações					
	Nent	Noc	Nsa	Épocas	QME	R ²
Rede01	1	11	16	136	178,655	36,16
Rede02	2	11	16	165	174,156	37,77
Rede03	3	11	16	104	171,161	38,84
Rede04	6	9	13	112	145,233	48,10
Rede05	4	10	12	130	133,868	37,87
Rede06	5	11	12	107	163,554	41,56
Rede07	6	11	12	182	146,143	47,78
Rede08	8	11	12	167	138,092	50,65
Rede09	10	11	12	150	139,847	50,03
Rede10	5	11	12	107	162,895	41,79
Rede11	11	11	11	75	151,943	45,71
Rede12	2	10	11	163	164,794	41,11
Rede13	5	10	11	258	142,245	49,17
Rede14	4	10	11	111	158,521	43,35
Rede15	6	10	8	112	152,365	45,27
Rede16	3	10	8	116	166,599	40,16
Rede17	3	9	5	84	10,233	96,31
Rede18	13	11	5	94	9,944	96,44
Rede19	11	10	5	223	17,933	93,57
Rede20	2	9	5	132	63,425	77,15
Rede21	5	9	5	59	59,452	78,58
Rede22	8	11	11	258	133,437	52,32




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída percentagem de incubabilidade na semana atual

Contribuição de cada entrada na saída: Pintos produzidos na semana atual

Modelos	Idade (sem)	Estação	Temp (°C)	URA (%)	Fêmeas	Machos	MortFemAcum (%)	MortMacAcum (%)	RacDia Fem (g)	RacDia Mac (g)	OvoSem	OvoInc	OvoInc Real
Rede01	100,00	-	-	-	-	-	-	-	-	-	-	-	-
Rede02	82,33	17,67	-	-	-	-	-	-	-	-	-	-	-
Rede03	65,79	-	17,13	17,08	-	-	-	-	-	-	-	-	-
Rede04	48,94	8,98	8,51	5,94	10,71	-	16,92	-	-	-	-	-	-
Rede05	59,87	11,26	-	-	17,00	11,87	-	-	-	-	-	-	-
Rede06	56,95	-	7,27	7,85	16,84	11,09	-	-	-	-	-	-	-
Rede07	49,57	8,88	8,45	7,53	15,90	9,67	-	-	-	-	-	-	-
Rede08	38,23	7,04	7,75	7,96	8,73	6,78	13,95	9,56	-	-	-	-	-
Rede09	20,23	7,01	6,83	6,33	9,51	7,32	10,52	7,61	15,69	8,95	-	-	-
Rede10	30,81	-	-	-	18,41	11,47	-	-	21,91	17,40	-	-	-
Rede11	15,75	5,52	6,73	6,23	8,08	7,10	7,22	6,55	8,80	8,51	19,51	-	-
Rede12	41,84	-	-	-	-	-	-	-	-	-	58,16	-	-
Rede13	27,67	15,37	11,66	10,67	-	-	-	-	-	-	34,63	-	-
Rede14	35,84	-	12,04	12,65	-	-	-	-	-	-	39,47	-	-
Rede15	22,99	12,68	11,62	11,25	-	-	-	-	-	-	19,46	22,00	-
Rede16	36,06	-	-	-	-	-	-	-	-	-	30,40	33,54	-
Rede17	28,14	-	-	-	-	-	-	-	-	-	35,66	-	36,2
Rede18	6,39	6,38	5,87	6,56	7,01	6,63	6,15	5,84	6,09	8,78	7,30	10,60	16,40
Rede19	10,64	5,29	7,36	9,07	8,29	7,07	4,65	7,11	10,18	11,64	-	-	18,70
Rede20	42,89	-	-	-	-	-	-	-	-	-	-	-	57,11
Rede21	23,79	9,33	13,32	11,24	-	-	-	-	-	-	-	-	42,32
Rede22	18,15	8,74	8,12	10,12	10,08	-	8,91	-	10,41	-	25,47	-	-

Informações das redes construídas para a saída: Pintos produzidos na semana atual

Modelos	Informações					R ²
	Nent	Noc	Nsa	Épocas	QME	
Rede01	1	11	16	136	12.745.867,459	66,08
Rede02	2	11	16	165	12.455.878,219	66,85
Rede03	3	11	16	104	12.568.020,019	66,55
Rede04	6	9	13	112	8.386.491,643	77,68
Rede05	4	10	12	130	9.869.692,103	73,74
Rede06	5	11	12	107	9.509.029,938	74,70
Rede07	6	11	12	182	8.560.825,449	77,22
Rede08	8	11	12	167	7.675.941,618	79,57
Rede09	10	11	12	150	7.933.681,463	78,89
Rede10	5	11	12	107	9.573.175,149	74,52
Rede11	11	11	11	75	7.996.834,223	78,72
Rede12	2	10	11	163	8.750.601,718	76,71
Rede13	5	10	11	258	7.805.039,489	79,23
Rede14	4	10	11	111	8.476.071,913	77,44
Rede15	6	10	8	112	8.046.271,389	79,61
Rede16	3	10	8	116	8.769.512,363	77,78
Rede17	3	9	5	84	735.257,378	98,14
Rede18	13	11	5	94	570.881,322	98,49
Rede19	11	10	5	223	350.482,534	99,07
Rede20	2	9	5	132	695.740,535	98,24
Rede21	5	9	5	59	720.257,927	98,18
Rede22	8	11	11	258	6.909.232,286	81,61




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída pintos produzidos na semana atual

Contribuição de cada entrada na saída: pintos a serem produzidos na semana seguinte

Modelos	Idade (sem)	Estação	Temp (°C)	URA (%)	Fêmeas	Machos	MortFemAcum (%)	MortMacAcum (%)	RacDia Fem (g)	RacDia Mac (g)	OvoSem	OvoInc	OvoInc Real	Pintos
Rede01	100,00	-	-	-	-	-	-	-	-	-	-	-	-	-
Rede02	84,96	15,04	-	-	-	-	-	-	-	-	-	-	-	-
Rede03	67,56	-	17,27	15,17	-	-	-	-	-	-	-	-	-	-
Rede04	45,72	9,51	8,06	5,29	12,77	-	18,65	-	-	-	-	-	-	-
Rede05	58,83	11,21	-	-	17,48	12,48	-	-	-	-	-	-	-	-
Rede06	56,15	-	6,67	7,85	18,04	11,29	-	-	-	-	-	-	-	-
Rede07	47,77	8,61	8,43	8,14	16,55	10,50	-	-	-	-	-	-	-	-
Rede08	35,57	7,29	9,66	8,12	10,26	7,27	13,01	8,82	-	-	-	-	-	-
Rede09	15,69	8,80	6,20	7,52	11,98	6,63	10,04	7,59	15,51	10,04	-	-	-	-
Rede10	30,23	-	-	-	17,28	10,78	-	-	24,85	16,86	-	-	-	-
Rede11	15,15	6,23	5,70	6,21	9,24	7,41	8,42	7,43	7,58	7,49	19,14	-	-	-
Rede12	38,91	-	-	-	-	-	-	-	-	-	61,09	-	-	-
Rede13	26,69	14,65	10,73	9,79	-	-	-	-	-	-	38,14	-	-	-
Rede14	36,26	-	13,78	12,35	-	-	-	-	-	-	37,61	-	-	-
Rede15	23,20	12,04	9,58	9,89	-	-	-	-	-	-	22,55	22,74	-	-
Rede16	37,87	-	-	-	-	-	-	-	-	-	31,98	30,15	-	-
Rede17	29,27	-	-	-	-	-	-	-	-	-	40,18	-	30,55	-
Rede18	7,28	7,07	5,61	7,23	8,04	7,05	7,43	5,45	6,01	8,00	7,43	11,34	12,06	-
Rede19	37,61	-	-	-	-	-	-	-	-	-	-	-	-	62,39
Rede20	8,26	6,81	4,13	7,54	6,79	6,67	5,61	5,11	5,81	8,11	5,88	7,74	10,66	10,88
Rede21	14,81	8,23	6,43	9,69	6,72	7,60	6,56	6,97	10,45	8,55	-	-	13,99	-
Rede22	46,90	-	-	-	-	-	-	-	-	-	-	-	53,10	-
Rede23	27,30	10,34	15,61	11,94	-	-	-	-	-	-	-	-	34,81	-
Rede24	13,93	10,00	5,43	9,22	8,22	9,00	6,69	4,59	9,71	10,82	-	-	-	12,39
Rede25	16,31	10,47	8,66	9,13	10,53	-	9,74	-	10,63	-	24,53	-	-	-

Informações das redes construídas para a saída: pintos a serem produzidos na semana seguinte

Modelos	Informações					R ²
	Nent	Noc	Nsa	Épocas	QME	
Rede01	1	11	16	136	12.510.647,709	60,38
Rede02	2	11	16	165	12.537.348,346	60,30
Rede03	3	11	16	104	12.212.520,938	61,33
Rede04	6	9	13	112	9.321.496,622	70,48
Rede05	4	10	12	130	9.939.241,891	68,52
Rede06	5	11	12	107	10.295.256,940	67,40
Rede07	6	11	12	182	9.585.009,252	70,28
Rede08	8	11	12	167	9.217.552,125	70,81
Rede09	10	11	12	150	8.861.196,478	71,94
Rede10	5	11	12	107	10.059.084,800	68,15
Rede11	11	11	11	75	8.874.726,534	71,90
Rede12	2	10	11	163	9.071.487,202	71,27
Rede13	5	10	11	258	9.178.885,192	70,93
Rede14	4	10	11	111	8.941.733,328	71,68
Rede15	6	10	8	112	8.620.378,359	74,59
Rede16	3	10	8	116	9.163.957,516	72,99
Rede17	3	9	5	84	9.184.928,888	73,19
Rede18	13	11	5	94	7.733.698,540	75,13
Rede19	2	8	2	116	11.950.031,564	65,12
Rede20	14	10	2	229	7.410.102,468	76,74
Rede21	11	10	5	223	8.352.178,687	73,86
Rede22	2	9	5	132	12.050.893,510	64,82
Rede23	5	9	5	59	11.528.474,629	66,35
Rede24	11	10	2	223	8.568.400,021	73,19
Rede25	8	11	11	258	8.402.817,123	73,39




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída pintos a serem produzidos na semana seguinte




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída pintos a serem produzidos na semana seguinte

Contribuição de cada entrada na saída: percentagem de eclosão na semana atual

Modelos	Idade (sem)	Estação	Temp (°C)	URA (%)	Fêmeas	Machos	MortFemAcum (%)	MortMacAcum (%)	RacDia Fem (g)	RacDia Mac (g)	OvoSem	OvoInc	OvoInc Real	Pintos
Rede01	100,00	-	-	-	-	-	-	-	-	-	-	-	-	-
Rede02	77,75	22,25	-	-	-	-	-	-	-	-	-	-	-	-
Rede03	64,67	-	19,11	16,22	-	-	-	-	-	-	-	-	-	-
Rede04	44,97	11,36	7,42	5,84	12,81	-	17,60	-	-	-	-	-	-	-
Rede05	54,74	14,62	-	-	18,30	12,34	-	-	-	-	-	-	-	-
Rede06	58,83	-	7,36	7,10	14,66	12,05	-	-	-	-	-	-	-	-
Rede07	41,43	10,57	9,31	8,39	17,91	12,39	-	-	-	-	-	-	-	-
Rede08	35,79	8,96	6,59	6,61	11,08	6,89	13,15	10,93	-	-	-	-	-	-
Rede09	20,43	9,25	6,02	6,29	8,95	6,97	10,39	7,15	15,28	9,27	-	-	-	-
Rede10	31,41	-	-	-	14,93	10,65	-	-	23,25	19,76	-	-	-	-
Rede11	15,75	6,48	6,18	6,23	9,55	6,31	8,37	6,80	8,74	7,38	18,21	-	-	-
Rede12	47,89	-	-	-	-	-	-	-	-	-	52,11	-	-	-
Rede13	28,11	16,68	12,45	9,94	-	-	-	-	-	-	32,82	-	-	-
Rede14	47,06	-	11,79	12,51	-	-	-	-	-	-	28,64	-	-	-
Rede15	30,86	12,82	10,79	9,26	-	-	-	-	-	-	18,31	17,96	-	-
Rede16	46,82	-	-	-	-	-	-	-	-	-	25,94	27,24	-	-
Rede17	39,30	-	-	-	-	-	-	-	-	-	28,79	-	31,91	-
Rede18	9,07	6,77	5,92	6,55	9,21	6,67	6,30	5,13	6,40	8,60	7,78	8,97	12,63	-
Rede19	50,93	-	-	-	-	-	-	-	-	-	-	-	-	49,07
Rede20	9,52	6,49	5,06	6,43	6,76	5,60	5,03	5,94	6,75	7,96	5,59	5,77	10,96	12,14
Rede21	15,01	7,71	6,63	7,48	7,31	7,35	6,65	7,06	9,06	11,58	-	-	14,16	-
Rede22	55,97	-	-	-	-	-	-	-	-	-	-	-	44,03	-
Rede23	33,37	10,62	14,65	10,52	-	-	-	-	-	-	-	-	30,84	-
Rede24	14,67	9,92	4,97	8,48	8,29	9,34	6,76	4,81	10,04	11,27	-	-	-	11,45
Rede25	20,51	10,50	6,96	7,72	12,97	-	8,29	-	12,76	-	20,29	-	-	-

Informações das redes construídas para a saída: percentagem de eclosão na semana atual

Modelos	Informações					
	Nent	Noc	Nsa	Épocas	QME	R ²
Rede01	1	11	16	136	9,959	67,94
Rede02	2	11	16	165	8,702	71,98
Rede03	3	11	16	104	9,251	70,22
Rede04	6	9	13	112	7,176	76,90
Rede05	4	10	12	130	7,053	77,29
Rede06	5	11	12	107	8,192	73,63
Rede07	6	11	12	182	7,248	76,67
Rede08	8	11	12	167	6,124	80,28
Rede09	10	11	12	150	4,448	85,68
Rede10	5	11	12	107	6,175	80,12
Rede11	11	11	11	75	5,262	83,06
Rede12	2	10	11	163	7,861	75,27
Rede13	5	10	11	258	4,954	84,05
Rede14	4	10	11	111	7,174	76,91
Rede15	6	10	8	112	6,836	78,12
Rede16	3	10	8	116	7,866	74,82
Rede17	3	9	5	84	8,069	74,29
Rede18	13	11	5	94	4,451	85,74
Rede19	2	8	2	116	7,802	75,15
Rede20	14	10	2	229	1,630	94,78
Rede21	11	10	5	223	3,605	88,45
Rede22	2	9	5	132	8,467	73,03
Rede23	5	9	5	59	7,779	75,22
Rede24	11	10	2	223	3,518	88,74
Rede25	8	11	11	258	4,539	85,39




Gráfico de dispersão da Predição *versus* Predição - Real do modelo escolhido para a saída percentagem de eclosão na semana atual

BIBLIOGRAFIA CITADA

ASTION, Michael L.; WILDING, Peter. The application of backpropagation neural networks to problems in pathology and laboratory medicine. **Arch Pathol Lab Med.**, v.116, p.995-1001, 1992.

BENIGNI, Romualdo; GIULIANI, Alessandro. Quantitative modeling and biology: the multivariate approach. **American Journal of Physiology** 266 (Regulatory Integrative Comp. Physiol. 35), p.R1697-R1704, 1994.

BRUNO, Maria. Targeting banking customers at the right point. **Bank Technology News**, New York, v.12, n.10, p.47, 52, 54-55, Oct. 1999.

CALLAN, Daniel E.; LASKY, Robert E.; FOWLER, Cynthia G. Neural networks applied to retrocochlear diagnosis. **Journal of Speech, Language, and Hearing Research**, v.42, p.287-299, 1999.

CHENG, Bing; TITTERINGTON, D. M. Neural Networks: a review from a statistical perspective. **Statistical Science**, v.9, n. 1, p. 2-54, 1994.

CHESINI, Sérgio. Métodos de cálculos de custos na avicultura: matrizes, pintos e frangos. In: Conferência APINCO de Ciência e Tecnologia Avícolas. **Anais**. p.81-83, 1989.

CROSS, Simon S.; HARRISON, Robert F.; KENNEDY, R. Lee. Introduction to neural networks. **Lancet**, v.346, p.1075-1079, 1995.

DYBOWSKI, Richard; GANT, Vanya. Artificial neural networks in pathology and medical laboratories. **Lancet**, v.346, p.1203-1207, 1995.

ELFADIL, A.A.; VAILLANCOURT, J.-P.; MEEK, A.H.; JULIAN, R.J. GYLES, C.L. Description of cellulitis lesions and associations between cellulitis and other categories of condemnation. **Avian Diseases**, v.40., p.690-698, 1996.

- ESTOCK, K. Nifty neural networks. **Independent Banker**, Sauk Centre, v.49, n.11, p.21-23, nov. 1999.
- FIALHO, Flávio Bello. Interpretação da curva de crescimento de Gompertz. **Comunicado Técnico n.237 Embrapa Suínos e Aves**, p.1-4, setembro 1999.
- FIALHO, Flávio Bello; LEDUR, Mônica Corrêa. Modelo matemático para curvas de produção de ovos. **Comunicado Técnico n.256 Embrapa Suínos e Aves**, p.1-3, setembro 2000a.
- FIALHO, Flávio Bello; LEDUR, Mônica Corrêa. Estimador da produção de ovos. **Comunicado Técnico n.257 Embrapa Suínos e Aves**, p.1-2, setembro 2000b.
- FREITAS, Alfredo Ribeiro de; ALBINO, Luiz Fernando T.; ROSSO, Luiz Afonso de. Estimativas do peso de frangos machos e fêmeas através de modelos matemáticos. **Comunicado Técnico n.68 Embrapa Suínos e Aves**, p.1-4, novembro 1983.
- FORSSTRÖM, Jari J.; DALTON, Kevin J. Artificial neural networks for decision support in clinical medicine. **Annals of Medicine**, n.5, v.27, p.509-517, 1995.
- FRANCO, José Luís Kieling. Custo das doenças avícolas. In: IV Encontro de qualidade industrial Ministério da Agricultura e Abastecimento e Indústrias Avícolas do RS. Imbé - RS, 1996.
- GOODMAN, P.H. & HARREL JR., F.E. Neural networks: advantages and limitations for bioestatistical modeling. <www.scs.unr.edu/nevprop>, 1999.
- GRAAT, E.A.M.; KOOIJ, E van der; FRANKENA, K.; HENKEN, A.M.; SMEETS, J.F.M.; HEKERMAN, M.T.J. Quantifying risk factors of coccidiosis in broilers using on-farm data based on a veterinary practice. **Preventive Veterinary Medicine**, v.33, p.297-308, 1998.
- IVEY, Frank J. Desenvolvimento e aplicação de modelos de crescimento para frangos de corte. In: I Simpósio Internacional ACAV - Embrapa sobre Nutrição de Aves, 1999, Chapecó- SC. **Anais do I Simpósio Internacional ACAV - Embrapa sobre Nutrição de Aves**, p.22-35, 1999.
- KIRBY, Yvonne Kochera; MCNEW, Ronald W.; KIRBY, John D.; WIDEMAN JR., Robert F. Evaluation of logistic versus linear regression models for predicting pulmonary hypertension syndrome (Ascites) using cold exposure or pulmonary artery clamp models in broilers. **Poultry Science**, v.76, p.392-399, 1997.
- KIRBY, Simon D.; ENG, P.; DANTER, Wayne.; GEORGE, Charles F.P.; FRANCOVIC, Tanya; RUBY, Ralph R.F.; FERGUSON, Kathleen A. Neural network prediction of obstructive sleep apnea from clinical criteria. *Chest*, v.116, n.2, 1999.

- KOVÁCS, Zsolt László. **Redes Neurais Artificiais: Fundamentos e Aplicações: um texto básico**. 2 ed. São Paulo: Edição acadêmica, 1996. 174p.
- KURZWEIL, R. Spiritual machines: the merging of man and machine. **The Futurist**, Washington, v.33, n.9, p.16-21, Nov. 1999.
- LEE, A.; ULBRICHT, C.; DORFFNER, G. Application of artificial neural networks for detection of abnormal fetal heart rate pattern: a comparison with conventional algorithms. *Journal of Obstetrics and Gynaecology*, v.19, n.5, 482-485, 1999.
- LIMA, Ideraldo Luiz; BERSCH, Francisco Xavier. Avaliação técnica dos equipamentos de frangos de corte e seus diferenciais. In: I Simpósio Brasil Sul de Avicultura. **Anais**. Chapecó – SC, p.89-103, 2000.
- MORRIS, Michael P. Economic considerations in prevention and control of poultry disease. In: SHANE, Simon N.; HALVORSON, David; HILL, Donna; VILLEGAS, Pedro; WAGES, Dennis. **Biosecurity in the poultry industry**. 1.ed. Pennsylvania (American Association of Avian Pathologists – AAAP): University of Pennsylvania, 1995, p.04-16.
- O'SULLIVAN, O. Who's that knocking on my portal? **USBanker**, New York, v.109, n.11, p.49-52, Nov. 1999.
- NORTH, Mack O.; BELL, Donald D. **Commercial Chicken Production Manual**. 4.ed. New York: Chapman & Hall, 1990, 1v.
- PINAZZA, Luiz Antonio; LAUANDOS, Ivan Pupo. Especial: Avicultura de corte – A atividade no Brasil – A revolução das aves. In: **Agroanalysis: A Revista de Agronegócios da FGV**. Instituto Brasileiro de Economia, Centro de Estudos Agrícolas, v.20, n.8, p.12-20, agosto de 2000.
- RIVAS, Octavio Campollo. Modelos matemáticos en medicina y biología. Bases teóricas y fundamentos. **La Revista de Investigación Clínica**, México - D.F., v.46, n.4, p.307-321, jul/ago 1994.
- ROBEY, Wade; GASPERONI, Giovanni; HARLOW, Harry. The IGM® as a tool for modeling broiler growth and variation. Disponível em <<http://www.novusint.com/nups/0495.htm>>. Acesso em: 21 nov. 2000.
- ROSENBLATT, Frank. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, v.65, n.6, p.386-408, 1958.

- ROUSH, W.B.; KIRBY, Y. Kochera; CRAVENER, T.L.; WIDEMAN JR., R.F. Artificial neural network prediction of ascites in broilers. **Poultry Science**, v.75, p.1479-1487, 1996.
- ROUSH, W. B.; CRAVENER, T. L. Artificial neural network prediction of amino acid levels in feed ingredients. **Poultry Science**, v.76, n.5, p.721-727, 1997.
- ROUSH, W.B.; CRAVENER, T.L.; KIRBY, Y. Kochera; WIDEMAN JR., R.F. Probabilistic neural network prediction of ascites in broilers based on minimally invasive physiological factors. **Poultry Science**, v.76, p.1513-1516, 1997.
- RUMELHART, David E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. Learning representations by back-propagating errors. **Nature**, v.323, p.533-536, 1986.
- SALLE, Carlos Tadeu Pippi & SILVA, Ari Bernardes da. Prevenção de Doenças / Manejo Profilático / Monitorização. In: BERCHIERI JUNIOR, Angelo, MACARI, Marcos. **Doenças das Aves**, Campinas - SP, 1ed., v.01, p.03-12, 2000.
- SALLE, Carlos Tadeu Pippi; SOARES, Roberto Bastarrica; CÉ, Milene Cristine; SILVA, Ari Bernardes; MORAES, Hamilton Luiz de Souza; NASCIMENTO, Vladimir Pinheiro do; GUAHYBA, Adriano da Silva. Modelos matemáticos para avaliar a resposta imune de aves à doença de Newcastle. **A Hora Veterinária** - Ano 17, Porto Alegre - RS, n.102, p.41-44, mar/abr/1998a.
- SALLE, Carlos Tadeu Pippi; CÉ, Milene Cristine; LORENZINI, Gustavo; SFOGGIA, Marcus Vinícius Bürgel; GUAHYBA, Adriano da Silva; MORAES, Hamilton Luiz de Souza; NASCIMENTO, Vladimir Pinheiro do. Correlation between aflatoxin and ocratoxin levels with production parameters in a poultry company. In: ASIA-PACIFIC POULTRY HEALTH CONFERENCE, 4., 1998, Melbourne - Australia. **Abstracts**. Melbourne: Australian Veterinary Poultry Association, p.131, 1998b.
- SALLE, Carlos Tadeu Pippi; CÉ, Milene Cristine; LORENZINI, Gustavo; SFOGGIA, Marcus Vinícius Bürgel; GUAHYBA, Adriano da Silva; MORAES, Hamilton Luiz de Souza; NASCIMENTO, Vladimir Pinheiro do. Correlation between aflatoxin and ocratoxin levels with production parameters in a poultry company. In: Western Poultry Disease Conference, 48., 1999, Vancouver - Canada. **Abstracts**. Vancouver: American Association of Avian Pathologists (AAAP), p.130, 1999a.
- SALLE, Carlos Tadeu Pippi; CÉ, Milene Cristine; SANTOS, Carlos Henrique C. dos; GUAHYBA, Adriano da Silva; NASCIMENTO, Vladimir Pinheiro do; MORAES, Hamilton Luiz de Souza. Use of statistical technique on the interpretation of routine serologic data produced by poultry industry. In: ASIA-PACIFIC POULTRY HEALTH CONFERENCE, 4., 1998, Melbourne - Australia. **Abstracts**. Melbourne: Australian Veterinary Poultry Association, p.148, 1998c.

- SALLE, Carlos Tadeu Pippi; CÉ, Milene Cristine; SANTOS, Carlos Henrique C. dos; GUAHYBA, Adriano da Silva; NASCIMENTO, Vladimir Pinheiro do; MORAES, Hamilton Luiz de Souza. Use of statistical techniques on the interpretation of routine serological data produced by a poultry industry. In: Western Poultry Disease Conference, 48., 1999, Vancouver - Canada. **Abstracts**. Vancouver: American Association of Avian Pathologists (AAAP), p.130, 1999b.
- SALLE, Carlos Tadeu Pippi; SOARES, Roberto Carlos Bastarrica; CÉ, Milene Cristine; GUAHYBA, Adriano da Silva; MORAES, Hamilton Luiz de Souza; NASCIMENTO, Vladimir Pinheiro do. Immune response assessment in turkey breeder (*Meleagris gallopavo*) under Newcastle vaccine virus by mathematical models. In: ASIA-PACIFIC POULTRY HEALTH CONFERENCE, 4., 1998, Melbourne - Australia. **Abstracts**. Melbourne: Australian Veterinary Poultry Association, p.148, 1998d.
- SALLE, Carlos Tadeu Pippi; SOARES, Roberto Carlos Bastarrica; CÉ, Milene Cristine; MORAES, Hamilton Luiz de Souza; NASCIMENTO, Vladimir Pinheiro do; GUAHYBA, Adriano da Silva. Immune response assessment in turkey breeders vaccinated against Newcastle disease using mathematical models. In: Western Poultry Disease Conference, 48., 1999, Vancouver - Canada. **Abstracts**. Vancouver: American Association of Avian Pathologists (AAAP), p.129, 1999c.
- SOARES, Roberto Carlos Bastarrica. Avaliação da resposta imunológica em reprodutoras de perus (*Meleagris gallopavo*) diante do vírus vacinal da doença de Newcastle através de modelos matemáticos. Porto Alegre: UFRGS, 1995. 75p. **Dissertação (Mestrado em Ciências Veterinárias)**. Faculdade de Veterinária, Universidade Federal do Rio Grande do Sul.
- SPECHT, Donald F. & SHAPIRO, Philip D. Generalization accuracy of Probabilistic Neural Networks compared with Back-Propagation Networks. **Proceedings of the International Joint Conference on Neural Networks**, June 8-12, 1, 887-892, 1991.
- THOLUDUR, Arun; RAMIREZ, W. Fred. Neural-network modeling and optimization of induced foreign protein production. **AIChE Journal**, v.45, n.8, p.1660-1670, 1999.
- TZSCHENTKE, B.; NICHELMANN, M.; POSTEL, T. Effects of ambient temperature, age and wind speed on the thermal balance of layer-strain fowls. **British Poultry Science**, v.37, p.501-520, 1996.
- UYSAL, M.; EL ROUBI, M. S. Artificial neural networks versus multiple regression in tourism demand analysis. **Journal of Travel Research**, Boulder, v.38, n.2, p.111-118, nov. 1999.

XIN, H. Assessing swine thermal comfort by image analysis of postural behaviors. **J. Anim. Sci.**, v.77, suppl.2/J, Dairy Sci., v.82, suppl.2/1999, p.1-9, 1999.

ZHANG, Zhiqun; MARQUARDT, Ronald R.; WANG, Guojie; GUENTER, Wilhelm; CROW, Gary H.; HAN, Zhengkang; BEDFORD, Michael R. A simple model for predicting the response of chicks to dietary enzyme supplementation. **J. Anim. Sci.**, v.74, p.394-402, 1996.